



UNIVERSIDAD
DE MÁLAGA

UNIVERSIDAD DE MÁLAGA
FACULTAD DE CIENCIAS ECONÓMICAS Y EMPRESARIALES

UN MODELO GLOBAL DE PREDICCIÓN DE QUIEBRA CON REDES NEURONALES

Doctorando: David Alaminos Aguilera

Tesis Doctoral

Dirigida por:

Dr. Manuel Ángel Fernández Gámez


Dr. Juan Antonio Campos Soria

OCTUBRE DE 2018



UNIVERSIDAD
DE MÁLAGA

AUTOR: David Alaminos Aguilera

 <http://orcid.org/0000-0002-2846-5104>

EDITA: Publicaciones y Divulgación Científica. Universidad de Málaga



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional:

<http://creativecommons.org/licenses/by-nc-nd/4.0/legalcode>

Cualquier parte de esta obra se puede reproducir sin autorización
pero con el reconocimiento y atribución de los autores.

No se puede hacer uso comercial de la obra y no se puede alterar, transformar o hacer obras derivadas.

Esta Tesis Doctoral está depositada en el Repositorio Institucional de la Universidad de Málaga (RIUMA): riuma.uma.es

MANUEL ÁNGEL FERNÁNDEZ GÁMEZ y JUAN ANTONIO CAMPOS SORIA, Profesores Titulares del Departamento de Finanzas y Contabilidad y de Economía Aplicada (Estructura Económica), respectivamente, de la Universidad de Málaga.

Certificamos:

Que bajo nuestra dirección, D. David Alaminos Aguilera, licenciado en Economía, licenciado en Ciencias Actuariales y Financieras y Máster en Análisis Económico y Empresarial, ha realizado el trabajo de investigación correspondiente a su tesis doctoral titulada:

“UN MODELO GLOBAL DE PREDICCIÓN DE QUIEBRA CON REDES NEURONALES”

Revisado el mismo, estimamos que puede ser presentado al Tribunal que ha de juzgarlo.

Y, para que conste a efectos de lo establecido en la normativa vigente, autorizamos la presentación de esta Tesis en la Universidad de Málaga.

Málaga a 12 de octubre de 2018.

Fdo. Manuel Ángel Fernández Gámez

Fdo. Juan Antonio Campos Soria

*"Vivir como hombres valientes y si la suerte es adversa,
hacer frente a sus golpes con corazones valientes"*

Marco Tulio Cicerón

Tras años de trabajo y sacrificio llega el momento de disfrutar esta tesis doctoral finalizada. Con ello, se culminan las expectativas y metas que me fijé hace muchos años, antes incluso de entrar en la Universidad. El recorrido que ha conllevado la presente tesis no sólo ha supuesto un hito de superación, sino también, un proceso de madurez personal que supone un privilegio con el que afrontar los inescrutables caminos del Señor. Espero que éste sólo sea el principio de un camino que seguramente promete ser difícil a la par que apasionante.

Me gustaría empezar dando las gracias a mis directores de tesis, en especial a Manuel Ángel Fernández, el cual tiene gran parte de culpa de mi tesis. Este trabajo es una muestra especial de todas las horas que hemos pasado juntos atrapados por nuestra obsesión de investigar. Te estaré eternamente agradecido por esta maravillosa oportunidad y por confiar en mí. También gracias a Juan Antonio Campos por sumarse a este proyecto, con quien he compartido muchos momentos de trabajo. Gracias por tu ayuda y por todos tus valiosos consejos.

Muchas gracias también a todo el Departamento de Finanzas y Contabilidad. Todos habéis contribuido a esta tesis. Gracias por vuestro apoyo sincero y por aceptarme en ser uno más de la familia. Gracias por los bonitos momentos y experiencias que he podido vivir con vosotros. Sois grandes profesionales, pero, sobre todo, grandes personas.

Gracias a todas aquellas personas que han ejercido alguna influencia en mi trayectoria académica. Tanto aquéllas que en este momento recuerdo como a las que no. Tanto aquéllas que están como que ya, por desgracia, no están. Porque todos habéis participado en que no dejara de luchar por mis sueños. Porque todos habéis dejado

vuestra pequeña huella en la persona que soy hoy y que me ha llevado hasta aquí. De corazón, gracias.

Por último, no podría olvidarme de mi familia. Gracias a mis padres y a mi hermana, las personas más importantes de mi vida, por estar siempre ahí, cuando más lo he necesitado, por apoyarme y soportarme, por creer en mí y por haber hecho de mí la persona que soy y seré. Os quiero y siempre lo haré.

Índice

INTRODUCCIÓN.....	15
CAPÍTULO 1: REVISIÓN DE LA LITERATURA E HIPÓTESIS DE INVESTIGACIÓN	21
1.1. LA PREDICCIÓN DE QUIEBRA EMPRESARIAL	24
1.2. PREDICCIÓN DE QUIEBRA EMPRESARIAL CON TÉCNICAS COMPUTACIONALES.....	33
1.3. MODELOS REGIONALES Y MODELOS GLOBALES DE PREDICCIÓN DE QUIEBRA	41
1.4. FORMULACIÓN DE HIPÓTESIS	53
BIBLIOGRAFÍA CAPÍTULO 1	57
CAPÍTULO 2: MÉTODOS DE CLASIFICACIÓN	79
2.1. LAS REDES NEURONALES ARTIFICIALES (RNA)	82
2.1.1. COMPONENTES Y ORGANIZACIÓN DE UNA RED NEURONAL ARTIFICIAL.....	84
2.1.2. ARQUITECTURA DE REDES NEURONALES	91
2.1.3. MODOS DE OPERACIÓN: APRENDIZAJE Y RECUERDO	93
2.1.4. ALGORITMO DE RETROPROPAGACIÓN.....	95
2.2. EL PERCEPTRON MULTICAPA (PMC).....	97
2.2.1. ESTRUCTURA DEL PMC.....	97
2.2.2. ANÁLISIS DE SENSIBILIDAD.....	99
2.3. CRITERIOS PARA LA SELECCIÓN DE MODELOS.....	101
2.3.1. MÉTODO DE VALIDACIÓN CRUZADA	102
2.3.2. CRITERIOS BASADOS EN LA INFORMACIÓN	103
2.3.2.1. El criterio de Akaike (AIC)	103
2.3.2.2. El criterio de Schwarz (BIC)	105

2.3.2.3. El criterio de Hannan-Quinn (HQC)	106
BIBLIOGRAFÍA CAPÍTULO 2	109
CAPÍTULO 3: DATOS Y VARIABLES	117
3.1. DATOS	119
3.1.1. OBTENCIÓN DE LOS DATOS	122
3.2. VARIABLES	125
3.2.1. PROCEDIMIENTO DE SELECCIÓN DE LAS VARIABLES	125
BIBLIOGRAFÍA CAPÍTULO 3	129
CAPÍTULO 4: RESULTADOS	133
4.1. RESULTADOS PARA T-1	135
4.1.1. MODELO GLOBAL.....	135
4.1.1.1. ANÁLISIS EXPLORATORIO	135
4.1.1.2. ANÁLISIS CONFIRMATORIO	143
4.1.2. RESULTADOS MODELO ASIA	147
4.1.2.1. ANÁLISIS EXPLORATORIO	147
4.1.2.2. ANÁLISIS CONFIRMATORIO	152
4.1.3. RESULTADOS MODELO EUROPA	155
4.1.3.1. Análisis Exploratorio	155
4.1.3.2. ANÁLISIS CONFIRMATORIO	160
4.1.4. RESULTADOS MODELO AMÉRICA	163
4.1.4.1. ANÁLISIS EXPLORATORIO	163
4.1.4.2. ANÁLISIS CONFIRMATORIO	168
4.1.5. COMPARACIÓN DEL MODELO GLOBAL CON LOS MODELOS REGIONALES EN T-1.....	171
4.1.6. MODELO CON VARIABLE REGIONAL	173
4.1.7. ANÁLISIS DE ROBUSTEZ	177
4.2. RESULTADOS PARA T-2	181
4.2.1. MODELO GLOBAL.....	181
4.2.1.1. ANÁLISIS EXPLORATORIO	181

4.2.1.2. ANÁLISIS CONFIRMATORIO	186
4.2.2. RESULTADOS MODELO ASIA.....	189
4.2.2.1 ANÁLISIS EXPLORATORIO	189
4.2.2.2. ANÁLISIS CONFIRMATORIO	194
4.2.3. RESULTADOS MODELO EUROPA	197
4.2.3.1. ANÁLISIS EXPLORATORIO	197
4.2.3.2. ANÁLISIS CONFIRMATORIO	202
4.2.4. RESULTADOS MODELO AMÉRICA	205
4.2.4.1. ANÁLISIS EXPLORATORIO	205
4.2.4.2. ANÁLISIS CONFIRMATORIO	210
4.2.5. COMPARACIÓN DEL MODELO GLOBAL CON LOS MODELOS REGIONALES EN T-2	213
4.2.6. MODELO GLOBAL CON VARIABLE REGIONAL	215
4.2.7. ANÁLISIS DE ROBUSTEZ.....	219
4.3.1 ANÁLISIS COMPARATIVO DE RESULTADOS	220
BIBLIOGRAFÍA CAPÍTULO 4.....	225
DISCUSIÓN DE RESULTADOS.....	229
CONCLUSIONES	241
BIBLIOGRAFÍA GENERAL.....	247

INTRODUCCIÓN

El estudio de la quiebra empresarial ha sido foco de atención de la literatura financiera a lo largo de las últimas décadas. Este gran esfuerzo investigador ha producido un enorme abanico de modelos de predicción, apoyados a su vez, en metodologías muy variadas (Sun, Li, Huang y He, 2014; Bellovary, Giacomino y Akers., 2007).

La importancia actual de los modelos de predicción de quiebra viene acrecentada por la reciente crisis financiera mundial, que demostró que incluso las mejores compañías internacionales deben vigilar constantemente su situación financiera, al igual que aquellas empresas con las que colaboran. El proceso de globalización ha dado lugar a la aparición de una compleja red de relaciones en el entorno empresarial. Esto ha originado un nuevo espacio de investigación, y la necesidad de crear nuevos modelos para predecir este fenómeno, no sólo a nivel de un país, sino para explicar las características comunes que comparten las empresas de un mismo entorno geográfico (Korol, 2013).

Uno de los caminos inicialmente tomados por la literatura sobre predicción de la quiebra fue el desarrollo de modelos contruidos con muestras formadas por empresas medianas y grandes, pertenecientes a los sectores industrial y comercial. Sin embargo, en esta etapa inicial, no se consideraron muestras específicas compuestas por empresas de un solo país, o por un conjunto reducido de países, y que por tanto bien podían considerarse como modelos regionales. Posteriormente, el desarrollo que tuvo la literatura en la construcción de modelos regionales se debió a la mera necesidad. No es de extrañar que hasta que no se desarrollaron bases de datos más completas no se llevaran a cabo modelos de predicción de quiebra centrados en conjuntos geográficos amplios. Recientemente, también han aparecido diversos modelos denominados globales, que han utilizado para su construcción muestras de empresas pertenecientes a diversas regiones del mundo.

Casi la totalidad de estos modelos globales han sido contruidos para predecir situaciones de dificultades financieras (Zhou, 2013; Platt y Platt, 2008), y tan sólo uno para predecir la quiebra empresarial (Alaminos, Del Castillo y Fernández, 2016).

Los resultados obtenidos en el estudio de Alaminos et al. (2016) confirman la superioridad del modelo global de predicción de quiebra en comparación con los modelos regionales. Estas conclusiones pueden ser importantes cuando se minimiza el coste de construir modelos de predicción, dada la existencia de variables financieras explicativas que son comunes a las regiones más importantes del mundo. Aún así, se demanda más investigación sobre modelos globales, relacionada con el incremento en la precisión y en el alcance de la información utilizada (Platt y Platt, 2008; Alaminos et al., 2016).

El presente trabajo trata de responder a la cuestión de investigación de si es posible mejorar la precisión de los modelos globales de predicción de quiebra existentes en la literatura previa. Para responder a esta cuestión se ha tenido en cuenta los excelentes resultados de clasificación que proporcionan los métodos computacionales tales como las redes neuronales artificiales (RNA) (Callejón, Casado, Fernández y Peláez, 2013), y se han contruidos tanto modelos regionales para Asia, Europa y Norte América, como modelos globales. En concreto, se ha utilizado el denominado Perceptrón Multicapa (PMC) y los resultados obtenidos han permitido constatar una mayor precisión de los métodos computacionales frente a las técnicas estadísticas tradicionales.

La estructura del presente trabajo de investigación es la siguiente. En el capítulo 1 se lleva a cabo un análisis de la literatura previa sobre predicción de quiebra. De este análisis se han obtenido conclusiones sobre los métodos aplicados y su perfeccionamiento,

sobre las variables empleadas, y sobre la evolución de los resultados obtenidos por los distintos modelos. Además, y atendiendo al enfoque de estudio adoptado, se ha analizado la literatura diferenciando entre modelos globales y modelos regionales. Este primer capítulo concluye aportando una clasificación de los estudios previos en la que se pone de manifiesto los principales argumentos utilizados y la brecha existente acerca de la superioridad de los modelos globales frente a los modelos regionales.

El capítulo 2 aborda los fundamentos del método de naturaleza computacional utilizado en el presente trabajo. Además, se presentan la técnica de validación cruzada y los principales criterios de selección de modelos, que han sido adicionalmente utilizados para el contraste de los resultados.

El capítulo 3 está dedicado al proceso de obtención de las muestras, a las variables utilizadas y a los criterios tenidos en cuenta para la selección de las mismas.

Por su parte, en el capítulo 4 se presentan los resultados del análisis empírico, dejando constancia de los modelos de predicción de la quiebra desarrollados y de la robustez de los mismos.

Finalmente, el trabajo concluye con una discusión sobre los resultados alcanzados, con la exposición de las principales conclusiones obtenidas y con el detalle de la bibliografía consultada.

CAPÍTULO 1: REVISIÓN DE LA LITERATURA E HIPÓTESIS DE INVESTIGACIÓN

En el presente capítulo se realiza un análisis de la literatura previa focalizado en los aspectos relacionados con la presente investigación. Inicialmente se realiza una revisión ordenada de la literatura existente sobre la predicción de quiebra, a partir de la cual se examina el desarrollo de las contribuciones efectuadas a lo largo de los últimos decenios. En esta primera indagación se estudian las variables a incluir en los modelos y los métodos utilizados para el desarrollo de los mismos. Posteriormente, se examinan los resultados de los modelos atendiendo al origen geográfico y a la pertenencia sectorial de las muestras utilizadas. También se ha tenido en cuenta los trabajos previos que han replicado, con modificaciones, los modelos más convencionales. Por ejemplo, aquellos referidos a los trabajos de Altman (1968), Ohlson (1980) y Zmijewski (1984), y que añadieron distintos cambios en métodos, muestras, periodos temporales y tratamiento de la información. Asimismo, también han tenido especial atención los trabajos que se ocuparon de comparar diferentes metodologías.

La revisión efectuada sobre la literatura de predicción de quiebra ha permitido obtener conclusiones precisas sobre los estudios realizados hasta la fecha y sobre dónde deberían orientarse la investigación futura. En este sentido, se ha podido constatar que, por un lado, hay estudios que tienen por objetivo elaborar un modelo de predicción para pronosticar la quiebra empresarial, y que facilitan clasificar a las empresas como quebradas o solventes. Estos son, con diferencia, la mayor parte de los trabajos. Dentro de este grupo podrían incluirse también aquéllos cuyo modelo propone servir de “advertencia temprana” anticipando el suceso de la quiebra. Por otro lado, también se ha constatado que en la última década han ido surgiendo modelos globales para la predicción de quiebra. Estos modelos han buscado los factores determinantes de la quiebra en empresas de una región geográfica relativamente amplia.

Finalmente, las conclusiones obtenidas del estudio realizado en el presente capítulo han posibilitado construir el marco de referencia en el que se encuadra la presente investigación y la formulación de las hipótesis que conciernen a la misma.

1.1. LA PREDICCIÓN DE QUIEBRA EMPRESARIAL

La literatura sobre predicción de quiebra se ha desarrollado con solidez desde la década de los sesenta. Desde entonces, han venido apareciendo estudios acerca de la predicción de quiebra empresarial ante la necesidad de establecer instrumentos prácticos con los que poder examinar la salud financiera de las empresas. La mayor parte de los numerosos estudios de investigación existentes se han dirigido a definir los factores que causan la insolvencia empresarial, con una especial incidencia en cómo predecirla antes de que ésta suceda. Esta inmensa tarea de investigación ha producido una extensa variedad de modelos, apoyados a su vez, en muy diversas metodologías (Dimitras, Zanakis y Zopounidis, 1996; Bellovary et al., 2007; Sun et al., 2014). El trabajo de Altman (1993) delimita el concepto de insolvencia e intenta reducir la distancia entre los términos de dificultades financieras y quiebra. Así, mientras que la "quiebra" cubre a las empresas en una situación legal de insolvencia, las "dificultades financieras" normalmente clasifican a las empresas de acuerdo con los índices de solvencia establecidos por un criterio de referencia. Por ejemplo, Zhou, Tam y Fujita (2016) realizan una clasificación multiclase de empresas chinas.

Del universo de empresas que han sido objeto de análisis, se puede establecer dos categorías generales: las compañías económicas y las compañías financieras. Ambos tipos de empresas presentan notables diferencias en su casuística y en sus características

financieras, por lo que han tenido un tratamiento diferente e independiente a lo largo de la literatura.

Acorde al enfoque de la presente tesis, nos centramos en la literatura sobre empresas económicas, donde los primeros autores en realizar trabajos empíricos sobre predicción de quiebra fueron Beaver (1966) y Altman (1968), utilizando el análisis univariante y el análisis multidiscriminante, respectivamente.

Por su parte, las variables financieras empleados por Altman (1968) han sido aplicadas en infinidad de trabajos posteriores de predicción de insolvencia, utilizándolas en técnicas estadísticas más avanzadas. A partir de estos primeros trabajos, el principal aspecto en la literatura, en lo concerniente a la predicción de quiebra, no sólo fue definir qué ratios o variables incorporar en los modelos, sino evaluar qué método estadístico era el más eficiente para predecir la quiebra. De este modo, los estudios se favorecieron de los progresos realizados por la estadística, facilitando la construcción de modelos con una mayor capacidad predictiva y una elevada robustez. Este es el principal motivo por el cual la literatura sobre predicción de quiebra se ha desarrollado con intensidad. Los avances de la literatura existente han sido realizados, pues, en paralelo al desarrollo de las diferentes metodologías aplicadas.

Una revisión de los métodos aplicados durante estos años de investigación nos posibilita comprender la evolución cometida en la literatura. Siguiendo esta pauta, los trabajos iniciales se desarrollaron a partir de los denominados clasificadores individuales puros. Dentro de estos clasificadores se encuentran los clasificadores estadísticos, que comprenden el análisis individual de variables, el análisis multidiscriminante (MDA) y las variantes de regresión logística (Logit), que están fundamentados en la teoría estadística y son, por lo general,

simples y fáciles de usar. El análisis individual de variables fue la primera técnica aplicada a la predicción de insolvencia. Previamente, el trabajo de Beaver (1966) planteó dos metodologías del análisis individual de variables, denominados análisis de perfil y modelo discriminante univariable. A través del análisis de perfil con un horizonte de cinco años previos a la quiebra, demostró que los resultados de ratios financieros en dos grupos de empresas (solventes e insolventes) eran enormemente diferentes, aumentando paulatinamente esa diferencia a medida que se aproximaba el momento de la quiebra.

Por su parte, Altman (1968) fue el primero en usar el MDA para la predicción de quiebra, metodología que pertenece a la familia del análisis discriminante multivariante. Altman creó el modelo "Z-score", consistente en una función discriminante lineal multivariable con cinco ratios financieros, y con un poder de predicción en el año previo a la quiebra muy superior al modelo discriminante univariable. Deakin (1972) utilizó el MDA con 14 ratios financieros de información contable, tomando como referencia a Beaver (1966) y a Altman (1968). Consiguió buenos resultados de precisión con información de tres años anteriores a la quiebra. Collins (1980) y Mensah (1983) también realizaron sendos trabajos de predicción de quiebra con MDA a principios de los 80. Ya entrados los años 90, y con la introducción de técnicas computacionales, la mayoría de los trabajos se centraron en la comparativa con estos nuevos métodos. Dimitras et al. (1996) analizaron 47 estudios previos sobre modelos de predicción de quiebra empresarial, resumiendo los métodos empleados y la variedad de ratios utilizados. El método predominante fue el análisis discriminante, y los ratios financieros más importantes provinieron de las categorías de solvencia y de rentabilidad.

Zmijewski (1984) utilizó ratios contables para estimar la probabilidad de quiebra mediante un modelo Probit. Demostró que el riesgo de quiebra disminuye de acuerdo con la rentabilidad de los activos y la liquidez, pero que aumenta con respecto al apalancamiento financiero. Utilizando también el modelo Probit, Kluger y Shields (1989) relacionaron la predicción de quiebra con la consistencia de la opinión auditora y la calidad de la información de los estados financieros. Los datos empíricos relativos al comportamiento del auditor proporcionaron apoyo a la idea de que los cambios en la designación del auditor antes de la quiebra pueden ser debidos a la pérdida de información desfavorable con el auditor actual.

La metodología Logit utiliza las funciones logísticas para convertir la variable dependiente de probabilidad de quiebra en una completamente continua, y que posteriormente es apropiada para acometer el análisis de regresión lineal. Ohlson (1980) fue el primer autor en aplicar el modelo Logit para explicar la relación entre el acaecimiento de la insolvencia y los ratios financieros, demostrando que dicho modelo era comparativamente mejor que el MDA para cuestiones de predicción de insolvencia. Usó compañías estadounidenses industriales, identificando cuatro factores determinantes tales como el tamaño de la empresa, la estructura financiera, el rendimiento y la liquidez a corto plazo. Zavgren (1985) aplicó el análisis factorial para determinar las variables explicativas del modelo Logit. Lo (1986) realizó una comparativa sobre los resultados de predicción entre los métodos MDA y Logit, mostrando este último una gran fiabilidad de precisión frente al tradicional MDA. Mossman, Bell, Swartz y Turtle (1998) expusieron una comparativa de cuatro tipos de modelos de predicción de quiebra basados en ratios de los estados financieros, flujos de dinero en efectivo, rendimientos de las acciones, y en las desviaciones estándar de dichas variables. Laitinen y Laitinen (2000) aplicaron Logit con la expansión de Taylor para

empresas estadounidenses. Shumway (2001) presentó un modelo de riesgo discreto para predecir la probabilidad de quiebra tomando variables contables y de mercado. Este modelo utilizó la información de todos los años de cada empresa mediante una regresión logística, diferenciándose del modelo logit estático, que sólo incorpora información de un solo año para cada observación. En la misma línea, Figlewski, Frydman y Liang (2012) exploraron cómo las condiciones económicas generales influyen en la insolvencia y en la calificación crediticia, incorporando modelos de intensidad de Cox. Con datos de empresas estadounidenses en el período 1981-2002, encontraron que ambos tipos de factores influyeron en el riesgo de impago.

Más recientemente, Balcaen y Ooghe (2006) revisaron 43 modelos de predicción de quiebra empresarial, que clasificaron en cuatro categorías según su frecuencia de uso: modelos univariados, modelos de índice de riesgo, modelos MDA, y modelos de probabilidad condicionada. Sin embargo, su revisión omitió el tipo de modelos basados en la teoría de precios de opciones (Vassalou y Xing, 2004) así como los modelos de riesgo (Shumway, 2001).

Utilizando variaciones de Logit, Hwang, Cheng y Lee (2007) emplearon un modelo Logit semiparamétrico, para una muestra aleatoria simple (prospectiva) y otro en el caso de control de los datos (basada en elección, retrospectiva). Así, este modelo de predicción propuesto puede ser aplicado directamente a los datos muestreados a partir de los dos diseños. Tras la simulación de datos reales confirman que este método de predicción produce pequeñas tasas de error con datos de fuera de la muestra. Sus resultados confirman también que reemplazando la discretización con funciones de densidad de probabilidad no aumenta el rendimiento del modelo. El resultado de esta variante de Logit mejoró el rendimiento del análisis discriminante, aportando una mayor información. Hauser y Booth (2011)

demonstraron que el modelo de Bianco y Yohai (BY) mejora la predicción en comparación con el estimador de máxima verosimilitud.

Smaraanda (2014) utilizó Logit para pequeñas y medianas empresas rumanas con el fin de comprobar el rendimiento de los modelos de predicción de quiebra dentro del contexto de la crisis financiera de 2007. Giordani, Jacobson, von Schedvin y Villani (2014) utilizaron únicamente el modelo Logit y consiguieron mejoras en la capacidad de predicción con la introducción de funciones spline, que tienen en cuenta las relaciones no lineales entre la quiebra y las variables del modelo. Li y Wang (2014) aplicaron Logit sobre un conjunto de datos de empresas chinas, revelando que las tasas de precisión de las predicciones del modelo propuesto, dentro y fuera de la muestra, son del 97,1% y del 94,1%, respectivamente. Por su parte, Oz y Simga-Mugan (2018) aplicaron los modelos de Altman (1968), Ohlson (1980), Taffer (1983), Zmijewski (1984) y Shumway (2001) para empresas de economías emergentes. Los resultados concluyeron que los modelos de Altman y Ohlson mostraron una precisión fiable, mientras que el resto de modelos tuvieron que ser recalibrados.

Por otro lado, se han realizado numerosos estudios en donde se utilizan diferentes variantes del modelo Logit. Son los casos de Tseng y Lin (2005) que proponen un análisis Logit de intervalo cuadrático basado en un enfoque de programación. Tseng y Hu (2010) plantearon un del modelo Logit de intervalo cuadrático a través del uso de un enfoque de programación para tratar las variables binarias en la regresión logística. Hensher y Jones (2007) utilizan un logit mixto, apoyándose en un modelo de quiebra de tres estados (multi-clase). Li y Mui (2010) construyeron un modelo híbrido compuesto de ratios de información contable y de mercado, incluyendo una variable de distancia a la quiebra. Li, Lee, Zhou y Sun (2011) propusieron el modelo Logit binario de subespacio aleatorio (RSBL) para generar un

grupo de diversos agentes de decisión desde varias perspectivas. Este modelo mejoró la capacidad predictiva de los modelos estadísticos previos. Brezigar-Masten y Masten (2012) realizaron un proceso de selección de variables predictivas para la quiebra basado en árboles de clasificación y en regresión no paramétrica. Consiguieron una buena capacidad predictiva utilizando dos tipos de clasificadores de quiebra, uno basado en ratios y otro basado en cuartiles.

También algunos autores han utilizado otras alternativas metodológicas de regresión. Liu (2004) empleó un modelo de corrección de errores (ECM) para investigar los determinantes de la insolvencia empresarial en el Reino Unido en relación con los fenómenos macroeconómicos vividos durante el período 1966-1999. Los resultados indicaron que los ratios de insolvencia están asociados con los tipos de interés, el nivel de crédito, los beneficios, el índice de precios al consumo y la tasa de nacimiento corporativo. Serrano-Cinca y Gutiérrez-Nieto (2013) utilizaron un análisis discriminante de mínimos cuadrados parciales (PLS-DA) para anticipar la crisis bancaria americana del periodo 2008-2011, y obtuvieron unos resultados no muy diferentes a los conseguidos a partir de MDA y las Máquinas de Soporte Vectorial (SVM). Más recientemente, Jabeur (2017) aplicó una regresión logística de mínimos cuadrados parciales (PLS-LR) para predecir la quiebra en empresas francesas, consiguiendo unos resultados de precisión aceptables, pero no mejorando el acierto mostrado por el modelo Logit.

Otro de los aspectos importantes que resaltan en la literatura sobre predicción de quiebra fue el desarrollo de modelos que habían sido contruidos utilizando una muestra multi-sectorial, y que podrían denominarse modelos descentrados. Tras la aparición de este tipo de modelos, la literatura se fue desarrollando también con los denominados modelos centrados, referidos a sectores económicos

específicos. En los modelos centrados han destacado, entre otros, los desarrollados para el sector agrícola. Los trabajos de Wasilewski y Madra (2008) y Vavrina et al. (2013) compararon diferentes técnicas de predicción de quiebra usando métodos tradicionales (Z Score, MDA y Logit) y nuevos enfoques (DEA-Data Envelopment Analysis) y (PFEP-Production function-based economic performance evaluation). Los resultados señalan que en el sector agrícola se consiguieron mejores resultados cuando se utilizó DEA.

Para el sector industrial, Bartoloni y Baussola (2014) y Grünenberg y Lukason (2014) crearon modelos de predicción de quiebra mediante MDA, DEA, RNA y Logit. Acorde a los resultados de acierto, las mejores metodologías utilizadas (de mayor a menor precisión) fueron: RNA, DEA, Logit y MDA. En referencia al sector de la construcción, Alaka et al. (2017) estudiaron los factores críticos que pueden provocar la quiebra. Sus resultados demostraron que la rentabilidad, la rotación de existencias, el endeudamiento, la liquidez, el crecimiento, la edad y las condiciones económicas generales influían en la probabilidad de quiebra. Para el sector comercial y de servicios, algunos autores como Keener (2013) y Antunes, Ribeiro y Pereira (2017) concluyeron que las empresas comerciales pequeñas y con menos empleados tienen una mayor probabilidad de quiebra. Los resultados concluyen en que las empresas con un menor ratio de caja sobre pasivos corrientes, reducidos márgenes de cash flow y altos niveles de endeudamiento sobre el capital poseen una mayor probabilidad de quebrar.

Utilizando un enfoque alternativo a la literatura financiera, algunos autores han aplicado metodologías propias de la teoría económica, principalmente del lado de la macroeconomía. Simons y Rolwes (2009) aplicaron un modelo macroeconómico para estimar las probabilidades de insolvencia empresarial. La primera parte del trabajo se centró en la relación entre las variables macroeconómicas y el

comportamiento predeterminado de las empresas holandesas. Demostraron una exigua relación significativa con el crecimiento del PIB y el precio del petróleo y, en menor medida, con los intereses y el tipo de cambio. La segunda parte del trabajo evaluó el comportamiento basado en un marco de escenario de estrés en torno al requisito de dos trimestres consecutivos de crecimiento cero del PIB, no encontrando influencias significativas sobre la probabilidad de insolvencia. Bruneaua, Bandtb y El Amria (2012) utilizaron una gran muestra de datos contables para empresas no financieras en Francia con objeto de estudiar las interacciones entre los shocks macroeconómicos y la fragilidad financiera de las empresas. Consideraron los vínculos en ambas direcciones, es decir, si las quiebras de las empresas se ven afectadas por las variables macroeconómicas, y si las quiebras determinan el ciclo económico. Estimaron las ecuaciones de predicción de la quiebra utilizando el enfoque de Shumway (2001) y estudiando la dinámica conjunta de la quiebra y de las variables macroeconómicas dentro de un modelo VAR (vector autorregresivo) de tipo exógeno estimado a nivel sectorial. Encontraron evidencia de vínculos recíprocos entre la tasa de quiebra y el crecimiento del PIB.

Finalmente, y con objeto de evaluar la eficacia de los diferentes modelos de predicción quiebra, en la literatura también han aparecido los trabajos de Agarwal y Taffler (2008), Das et al. (2009), y Bauer y Agarwal (2014). Estos trabajos toman en cuenta el desempeño de los modelos basados en factores procedentes de la contabilidad, del mercado y de riesgos. Según Agarwal y Taffler (2008), hay poca diferencia en la precisión predictiva de los modelos basados en información contable respecto a los basados en el mercado. Sin embargo, el uso de modelos basados en la contabilidad permite un mayor nivel de evaluación de la actividad de crédito ajustada al riesgo. Bauer y Agarwal (2014) utilizaron modelos de riesgo con información contable y de mercado, comparándolos con el enfoque tradicional del

modelo basado en información tipo Z-score. Con una muestra de datos de empresas británicas, los modelos de riesgo (hazard) fueron superiores a los modelos tradicionales de predicción de quiebra.

Los últimos trabajos realizados sobre la predicción de quiebra han llegado a conclusiones que podrían servir para resumir, a grandes rasgos, los principales hallazgos en torno a dicha cuestión. Tal es el caso de Oz y Yelkenci (2017), que trataron el estado teórico de las dificultades financieras en referencia a las variables más significativas a lo largo de la literatura. Sus resultados indican que las variables más explicativas han sido las relacionadas con la rentabilidad, y en menor medida, con la liquidez. También el caso reciente de Jones, Johnstone y Wilson (2017), que realizaron una comparativa entre las técnicas estadísticas (Logit y MDA) y computacionales (RNA, SVM, métodos de boosting generalizado, AdaBoost y random forests) y concluyeron que RNA es la metodología con mayor precisión, aunque Logit es la técnica más fiable.

1.2. PREDICCIÓN DE QUIEBRA EMPRESARIAL CON TÉCNICAS COMPUTACIONALES

Los llamados clasificadores de inteligencia computacional o artificial comprenden técnicas como RNA, SVM, los Algoritmos de Evolución (EA), el Razonamiento Basado en Casos (CBR), el Rough Set (RS) y Árboles de Decisión (DT). Estas metodologías también han sido aplicadas en la predicción de quiebra y están apoyadas por unos notables resultados en los estudios genéricos sobre inteligencia artificial, ofreciendo la ventaja de no estar sujetas a los rigurosos supuestos exigidos por las técnicas estadísticas.

A principios de la década de los 90 las RNA comienzan a ser empleadas en los estudios de predicción de quiebra en los trabajos de Tam (1991) y Tam y Kiang (1992). El modelo de RNA está basado en un grupo de neuronas artificiales interconectadas que tratan la información aplicando un enfoque de conexión para realizar el cálculo. De igual manera, la RNA probabilística fue utilizada en la predicción de insolvencia y aplicada en las teorías de toma de decisiones de tipo bayesianas para la estimación de la concertación probabilística en grupos de datos (Wu et al., 2008; Yang et al., 1999). Odom y Sharda (1990) y Wilson y Sharda (1994) aplicaron MDA y lo compararon con RNA. Jo, Han y Lee (1997) realizaron también una comparativa del MDA con la predicción basada en casos y con RNA, resultando que RNA fue el método de mayor precisión. Charitou, Neophytou y Charalambous (2004) compararon los resultados de predicción del modelo de Altman (1968) a través de la aplicación de Logit y RNA. El modelo desarrollado determinó como ratios significativos los flujos de efectivo operativos, el apalancamiento financiero y los índices de rentabilidad. Callejón et al. (2013) utilizaron una variante de RNA, concretamente el PMC, en su objetivo de optimizar los resultados de los modelos RNA que se estaban empleando en los estudios empíricos. Tinoco y Wilson (2013) trataron la predicción de dificultades financieras y la quiebra mediante ratios contables, de mercado y macroeconómicos utilizando Logit y RNA para empresas no financieras del Reino Unido. Demostraron que puede obtenerse resultados precisos con los tres tipos de variables, y que dichas variables son complementarias. Barboza, Kimura y Altman (2017) compararon técnicas estadísticas (Logit y MDA) y métodos computacionales (RNA, SVM, bagging, boosting y random forest) obteniendo éstos últimos un 10% de precisión mayor que los métodos estadísticos.

Yang, Platt y Platt (1999) propusieron RNA probabilísticas utilizando empresas estadounidenses de la industria del petróleo y del

gas y cinco ratios financieros (flujos de caja para los activos totales, la deuda total respecto a los activos totales, gastos de exploración respecto a las reservas totales, pasivos corrientes respecto a la deuda total y la evolución de las reservas totales). El estudio concluyó que RNA probabilísticas obtienen una alta precisión de la clasificación mediante el uso de datos no deflactados. Anandarajan, Lee y Anandarajan (2001) combinaron RNA con el denominado Algoritmo Genético, y compararon esta combinación con MDA usando el marco teórico de Zmijewski (1984). Una comparación similar fue realizada por Pompe y Bilderbeek (2005) para pequeñas empresas industriales belgas, y concluyeron sobre el éxito de la combinación entre RNA y Algoritmo Genético. Berg (2007) hace una comparación de RNA con otras técnicas como análisis discriminante lineal (LDA), modelos lineales generalizados (GLMs), modelos aditivos generalizados (GAMs), obteniendo con este último mejores resultados para empresas noruegas.

Alfaro, García, Gámez y Elizondo (2008) realizaron una comparativa de RNA con el algoritmo AdaBoost para empresas europeas, consiguiendo una reducción de los errores cometidos por RNA. Tseng y Hu (2010) trataron de realizar una comparativa, usando cuatro técnicas diferentes -Logit, Logit de intervalo cuadrático, PMC y Red de Función de Base Radial (RBFN)- para la predicción de la quiebra de una muestra de empresas públicas británicas del sector industrial. El intervalo de resultados osciló entre el 91.15% y el 77.05%, siendo el método RBFN el que mostró una precisión superior. Por último, Lee y Choi (2013) compararon PMC con MDA utilizando una muestra de empresas coreanas de diferentes sectores. La predicción con PMC fue mejor que con MDA. También Ravi y Krishna (2014) propusieron un nuevo método de imputación de datos con redes neuronales auto asociativas basadas en regresión general, con las que obtuvieron

mejores resultados que con métodos híbridos de RNA, como los basados en optimización de enjambre de partículas, ondícula y RBFN.

Recientemente, Chung et al. (2016) presentaron una nueva variante de RNA llamada modelo cerebeloso de redes neuronales (CMRNA), siendo una técnica que imita el funcionamiento del cerebelo de un ser humano. Obtuvieron mejores resultados que con otras variantes de RNA a partir del estudio de empresas quebradas taiwanesas.

La superioridad de las RNA sobre los métodos estadísticos convencionales ha sido debida, principalmente, a su alta capacidad de aplicación práctica y a la no necesidad de una relación previa entre las variables. Sin embargo, en comparación con las metodologías estadísticas, las RNA requieren de un conjunto de datos de entrenamiento superior para producir un modelo estable, sin descuidar que un entrenamiento excesivo tiende a originar sobreajuste, reduciendo la estabilidad predictiva de la muestra seleccionada para el testeo. Con objeto de tratar este tipo de preocupaciones, Sun et al. (2014) realizaron una revisión del estado del arte de la predicción de las dificultades financieras tratando la modelización, el muestreo y la selección de variables, y obtuvieron como principal conclusión que la característica principal en la predicción de dificultades financieras es encontrar un modelo preciso, pero simple.

Como se expuso anteriormente, SVM ha sido otro de los métodos computacionales utilizado en la predicción de quiebra. Se basa en el principio de minimización del riesgo estructural en lugar del principio de minimización del riesgo empírico, siendo un robusto clasificador de datos y un instrumento de cálculo funcional (Wang et al., 2005). Tanto Shin et al. (2005) como Min y Lee (2005) utilizaron las SVM para predecir la quiebra de compañías surcoreanas, y ambos trabajos

concluyeron en que el método mejora la precisión obtenida con MDA, Logit y RNA. También Hui y Sun (2006) y Ding et al. (2008) escogieron SVM para realizar un análisis empírico sobre predicción de quiebra de empresas chinas y sus resultados mostraron conclusiones similares a las anteriores. Por su parte, Chaudhuri y De (2011) realizaron una derivación de SVM de tipo borroso, con el objetivo de analizar su variabilidad respecto al método original. Los resultados mostraron una mejor precisión de clasificación con empresas estadounidenses procedentes de crash bursátil de principios del 2000. Yang, You y Ji (2011) aplican SVM combinada con mínimos cuadrados parciales con el objeto de seleccionar los indicadores financieros más relevantes para predecir la quiebra y al mismo tiempo identificar el papel de cada variable en el proceso de predicción. Ribeiro, Silva, Chen, Vieira y das Neves (2012) realizaron tres variantes de SVM: el original, el aprendizaje multi-tarea y el modelo de riesgo de impago. Los resultados detallaron que éste último fue el mejor, utilizando empresas francesas de diferentes sectores. En cambio, Bose y Pal (2006) examinaron el rendimiento de las SVM con el de las RNA y MDA, obteniendo las SVM peores resultados.

Junto a los clasificadores mencionados, también han sido utilizados los Algoritmos de Evolución (EA). Los EA son algoritmos genéricos fundamentados en los métodos metaheurísticos que utilizan mecanismos basados en la teoría de la evolución biológica, como la reproducción, la mutación y la selección. Varetto (1998) empleó EA para obtener funciones lineales sin limitaciones estadísticas y sus respectivas reglas discriminantes. No obstante, el rendimiento de este modelo de predicción no fue superior al mostrado por MDA. Shin y Lee (2002) aplicaron los EA para explorar la selección de las variables financieras y delimitar las reglas discriminantes empíricas en la predicción de quiebra. De igual manera, Rafiei Manzari y Bostanian (2011) también concluyeron que EA arrojan una precisión inferior a las

RNA. Etemadi et al. (2009) examinaron el uso de la Programación Genética (GP), siendo esta una especialización de EA para optimizar una población de programas de acuerdo a una función de ajuste que evalúa la capacidad de cada programa para llevar a cabo la tarea asignada, en la predicción de insolvencia para empresas iraníes, donde la prueba de McNemar indicó que superan a MDA. Por consiguiente, las técnicas apoyadas en EA pueden producir reglas más sencillas de interpretar que las metodologías RNA o SVM, pero tiene una precisión más limitada y serían más apropiados para ser combinadas con otros clasificadores.

Por su parte, el método denominado Razonamiento Basado en Casos (CBR) utiliza el algoritmo de K-vecinos más cercanos, y se basa en intentar predecir los sucesos objetivos a partir de unos sucesos parecidos. La principal ventaja de CBR es su sencilla comprensión y su alto rendimiento predictivo. Tras comparar CBR, RNA y MDA, Jo y Han (1996, 1997) concluyeron que no había diferencias entre MDA y CBR, aunque el CBR funcionaba bien con muestras pequeñas. Park y Han (2002) y Sun y Han (2006) emplearon la ponderación del algoritmo de K-vecinos más cercanos para predecir la quiebra, mejorando de modo importante la precisión. Más recientemente, Borrajo et al. (2011) diseñaron un sistema multi agente para la toma de decisiones de negocios y la predicción de la quiebra, añadiendo un algoritmo CBR al agente del núcleo. Ouenniche, Bouslah, Cabello y Ruiz (2017) aplicaron un clasificador basado en el método de punto de referencia. El diseño utiliza el procedimiento de punto de corte en las observaciones dentro de la muestra y la elección del k-vecino más cercano como un clasificador fuera de la muestra.

Dimitras et al. (1996) y McKee (2000) aplicaron la teoría del Rough Set (RS) (en español, Conjunto Aproximado) para construir un modelo de predicción de quiebra para empresas griegas y americanas,

respectivamente. RS alberga diferentes ventajas, tales como unas reglas discriminantes de fácil compresión, apoyo a las reglas de decisión, y combinaciones de factores cualitativas y cuantitativas sin exigencias de tratamiento estadístico de la probabilidad. No obstante, diversas muestras pueden originar distintos conjuntos de reglas de decisión y, por lo tanto, RS experimentaría deficiencias derivadas de una universalidad limitada.

Friedman, Altman y Kao (1985) y McKee y Greenstein (2000) aplicaron el método denominado Árboles de Decisión (DT) para predecir la quiebra. Sun y Li (2008) formularon un algoritmo de minería de datos fundamentado en la inducción de factores, ganancia de información y DT, y lo probaron para una muestra de empresas chinas. Gepp, Kumar y Bhattacharya (2010) y Li, Huang, Sun y Lin (2010) también concluyeron que los resultados de clasificación con DT son superiores a los obtenidos con MDA. Chen (2011) realizó una comparativa entre los DT y Logit para compañías taiwanesas y constató que DT ofrece mayor precisión que Logit en el corto plazo (inferior a un año), mientras que la precisión del Logit es superior en el largo plazo (aproximadamente, un año y medio).

Otros métodos computacionales también han sido utilizados en la predicción de quiebra. Por ejemplo, los clasificadores Bayesianos (Sarkar y Sriram, 2001; Gesel et al., 2006; Sun y Shenoy, 2007; Wu, 2011), DEA (Pendharkar, 2002; Cielen et al., 2004; Premachandra et al., 2011; Ouenniche y Tone, 2017), y Programación Lineal Multi-criterio (Kwak et al., 2011). No obstante, los referidos estudios concluyeron que dichos métodos actuaban al mismo nivel de precisión que MDA, Logit, DT y SVM. Adicionalmente, Ryu y Yue (2005) impulsaron una nueva metodología de optimización matemática denominado Separación Isotópica (IS), obteniendo una precisión superior a DT, RS, RNA y MDA en una prueba predictiva de quiebra con

datos de empresas estadounidenses. Zhou y Lai (2017) investigaron los modelos de AdaBoost. Sus resultados mostraron que el algoritmo AdaBoost combinado con los métodos de imputación tiene una gran precisión predictiva y es una alternativa útil para la predicción de quiebra cuando existan datos perdidos.

En los últimos años, la mayor parte de la investigación se ha orientado hacia metodologías híbridas, basadas en varios algoritmos, siendo RNA, CBR y SVM los métodos preferidos para la combinación con otras técnicas. Back et al. (1996) y Anandarajan et al. (2001) combinaron RNA con EA. Utilizaron EA para la función de selección de las variables de los nodos de entrada de la RNA y determinaron que la combinación EA-RNA aumentaba la precisión. Ravisankar, Ravi y Bose (2010) y Ravisankar y Ravi (2010) crearon diferentes modelos híbridos siguiendo esta pauta, y concluyeron que cualquier híbrido compuesto por PMC, RNA probabilísticas, programación genética y RS arrojan el mejor nivel de precisión. Yeh Chi y Hsu (2010) plantearon un modelo híbrido de dos etapas que fusiona RS y SVM, denominado RST-SVM. Usaron RS para eliminar las características repetidas y SVM para predecir la quiebra. Sus resultados mejoraron a los obtenidos con el híbrido RST-BNP. Lin et al. (2011) entrenaron un modelo SVM después de la reducción de atributos de dimensionalidad con el Algoritmo de Mapeo Isométrico (ISO-MAP), lo que condujo a una mayor precisión en comparación con otros métodos híbridos.

Ahn y Kim (2009) y Li et al. (2010) desarrollaron un modelo de predicción de quiebra que combinaba EA y CBR, donde EA era empleado para asignar las ponderaciones de los atributos y la selección de casos de manera simultánea. Este clasificador híbrido obtuvo una precisión mayor que el simple CBR, pero requirió más tiempo y más recursos de modelización. Cho et al. (2010) utilizaron los DT para trazar las variables explicativas empleando como pauta la distancia de

Mahalanobis. Kim, Jo y Shin (2016) estudiaron la efectividad de un método híbrido utilizando una técnica de cluster y EA basados en el modelo de RNA para equilibrar la proporción entre la clase minoritaria y la clase mayoritaria. El objetivo de este trabajo fue constituir el mejor conjunto de datos de entrenamiento adecuado para disminuir el desequilibrio de datos y mejorar la precisión de la clasificación. El método propuesto se aplicó con éxito al problema de predicción de quiebra utilizando datos financieros para pequeñas y medianas empresas. Chou, Hsieh y Qiu (2017) examinaron la precisión de un híbrido entre EA y el algoritmo de cluster difuso. En sus experimentos aplicaron dos conjuntos de ratios financieros y el clasificador difuso desarrollado se comparó con el conocido clasificador de redes neuronales de propagación hacia atrás (BPRNA), obteniendo resultados satisfactorios. DuJardin (2018) construyó híbridos individuales a partir de clasificadores convencionales, aumentando el número de nodos y capas. Concluyó que un conjunto de DT predice mejor que un solo DT, pero no necesariamente mejor que RNA o que SVM.

1.3. MODELOS REGIONALES Y MODELOS GLOBALES DE PREDICCIÓN DE QUIEBRA

Como se expuso con anterioridad, otros términos utilizados en la literatura son los que se refieren a modelos regionales (que consideran empresas de un país o región) y a modelos globales (construidos con muestras de varios países o regiones). Los estudios que integran este tipo de modelos son de muy distinta naturaleza. La la mayor parte de estudios existentes son de naturaleza regional, pues han focalizado en la predicción de la quiebra de empresas de un solo país. Por ejemplo, Serrano-Cinca (1997) en el caso de compañías españolas, o Charalambous, Charitou y Kaourou (2000) con compañías estadounidenses.

Por su parte, y entre los estudios que incorporan la característica global, destacan un limitado número de investigaciones. Así, Tsai (2009) tuvo en cuenta empresas australianas, alemanas y japonesas, y Chen, Yang, Wang, Liu, Xu, Wang y Liu (2011) empresas polacas y australianas. Zhou (2013) construyó un modelo con compañías estadounidenses y japonesas, aplicando un conjunto de métodos (MDA, Logit, DA, RNA y SVM).

Pero, además de incorporar esta peculiaridad global, los enfoques empleados en este tipo de estudios son diferentes. Pindado Rodrigues y de la Torre (2008) desarrollaron un modelo de estimación de impago utilizando como conjunto de datos compañías de Estados Unidos y del resto de países del G-7. Este trabajo ofreció una aproximación a la posibilidad de cuantificar la probabilidad de caer en problemas financieros, y que podía ser empleada para distintos países y periodos temporales. El modelo presentó mucha estabilidad en cuanto a la significatividad, consistencia de los coeficientes y poder de clasificación.

El trabajo de Platt y Platt (2008) se centró en analizar las dificultades financieras de compañías industriales en tres áreas geográficas del mundo (Estados Unidos, Europa y Asia), utilizando el concepto de dificultades financieras en un sentido amplio con metodología Logit. No obstante, en el tratamiento de los datos sólo consideraron muestras de entrenamiento, sin verificar el modelo en muestras de testeo. Y tampoco utilizaron un horizonte temporal de algunos años previos a la situación de dificultad financiera con objeto de intentar anticiparse al suceso.

Chauhan et al. (2009) aplicaron una Red Neuronal Ondícula (WRNA) con un algoritmo de evolución diferencial (DE) para una muestra de bancos estadounidenses, turcos y españoles. La red

resultante recibe el nombre de red neuronal wavelet entrenada para la evolución diferencial (DEWRNA). El rendimiento de DEWRNA se comparó con el umbral que acepta WRNA entrenada (TAWRNA) y los resultados mostraron que DEWRNA y TAWRNA superaron al WRNA original en términos de precisión y sensibilidad en todos los problemas. Además, DEWRNA superó a TAWRNA en términos de precisión y sensibilidad en todas las muestras excepto en el conjunto de datos de los bancos turcos.

Ravisankar y Ravi (2010) utilizaron una muestra muy diversa, con bancos españoles, turcos, estadounidenses y británicos, empleando el método Grupo de Gestión de Datos (GMDH), la Red Neuronal de Propagación en Contador (CPRNA) y el Mapa Difuso de la teoría de la Resonancia Adaptable (ARTMAP difuso). La eficacia de cada una de estas técnicas se probó utilizando cuatro conjuntos de datos diferentes pertenecientes a bancos españoles, turcos, británicos y estadounidenses. Los resultados indicaron que GMDH superó al resto de técnicas con una precisión promedio por encima del 90%.

Laitinen y Suvas (2013) analizaron, en primer lugar, la predicción de las dificultades financieras en diferentes países europeos. En segundo lugar, compararon la predictibilidad entre países. En tercer lugar, también investigaron las posibilidades de desarrollar un modelo genérico uniforme para predecir la insolvencia en cada país de Europa. La muestra incluyó más de un millón de empresas activas y decenas de miles con dificultades financieras de 30 países europeos. Para cada país, se estimó un modelo de predicción propio y la precisión de cada uno de ellos se comparó entre países. Finalmente, se estimó un modelo único para la muestra que incluyó todos los países. Los resultados mostraron que existen diferencias en la forma y en la precisión de los modelos en los diferentes países europeos, pero que, sin embargo, es

posible desarrollar un modelo único que obtenga un nivel de precisión razonablemente alto para la mayoría de los países.

Por otro lado, el estudio de Korol (2013) integró el enfoque de la quiebra y realizó una comparación entre dos regiones. Construyó un modelo de riesgo de quiebra fundamentado en el concepto de sistema de "Advertencia Temprana", utilizando la estructura del modelo de Altman a partir de países de América Latina (México, Argentina, Brasil, Chile y Perú) y de Europa Central (Polonia). Empleó MDA, DT y RNA, y 14 ratios financieros como posibles variables. Concluyó que los errores de tipo I eran más elevados en las empresas latinoamericanas que en las compañías europeas. Los resultados constataron además que el modelo DT tiene una mayor efectividad que RNA en las muestras empleadas. Pero hay que advertir que este estudio se centró en realizar una comparación entre los modelos de América Latina y Europa Central y no se ocupó de cubrir la principal brecha de la investigación que es la creación de modelos específicos para cada región de importancia en el mundo. Únicamente alcanzó a comparar métodos y resultados entre dos regiones. Además, la muestra de Europa Central utilizada en este estudio no es del todo suficiente, al incluir sólo empresas polacas en la muestra europea. Tampoco tiene en cuenta a la composición industrial de las muestras ni la justificación de los ratios financieros elegidos.

Maghyreh y Awartani (2014) emplearon Logit multi-periodo para bancos de países del Consejo de Cooperación del Golfo durante el periodo 2000-2009 y determinaron un conjunto de factores significativos de dificultades financieras que se utilizaron posteriormente para predecir la probabilidad de estrés bancario en dichos países. Tsai, Hsu y Yen, (2014) emplearon PMC, SVM y DT combinados con los métodos de boosting y bagging, para una muestra constituida por un conjunto de empresas alemanas, japonesas y

australianas. Sus resultados mostraron la superioridad de los conjuntos DT mediante boosting sobre los demás clasificadores.

Betz, Oprica, Peltonen y Sarlin (2014) desarrollaron un modelo de alerta temprana para detectar las dificultades financieras de bancos europeos en los 3 años previos a la quiebra mediante Logit. El hallazgo principal del modelo es la complementación de las vulnerabilidades específicas de los bancos con indicadores de desequilibrios macro-financieros.

Alaminos et al. (2016) utilizaron un marco metodológico de regresión logística para construir modelos predictivos de quiebra para Asia, Europa y América, y otros modelos globales para todo el mundo. Este estudio tuvo por objeto construir un modelo global con una gran capacidad de predicción de quiebra en cualquier región del mundo. Los resultados obtenidos han permitido confirmar la superioridad del modelo global en comparación con los modelos regionales durante períodos de hasta tres años antes de la quiebra, con rangos de precisión de entorno al 90% para un horizonte temporal de un año, alrededor del 85% para dos años previos a la quiebra y cercano al 80% para un horizonte de tres años.

Por último, Altman, Iwanicz-Drozdowska, Laitinen, y Suvas (2017) evaluaron el rendimiento de clasificación del modelo Z-Score en predicción de quiebra y en otros tipos de dificultades empresariales, con el objetivo de examinar la utilidad del modelo para todas las partes, especialmente para bancos que operan internacionalmente y necesitan evaluar el riesgo de fracaso de las empresas. Realizaron una revisión del modelo Z-score con empresas separadas de 31 países, en su mayoría europeos, consiguiendo un intervalo de precisión entre el 70% y el 80%. Los autores mostraron como futura línea de investigación

para la mejora del trabajo la inclusión de variables de mercado que recojan la influencia del nivel país y el uso de métodos alternativos.

Una síntesis de la revisión de la literatura sobre predicción de quiebra realizada en el presente capítulo aparece en las tablas 1.1 y 1.2.

Tabla 1.1. Principales estudios empíricos de predicción de quiebra

AUTOR Y AÑO	MUESTRA	SECTOR	METODOLOGÍA	PAÍS	RESULTADOS		
					Años antes de quiebra		
					1	2	3
Beaver (1966)	158 empresas	Industrial amplio	A. Univariante	EE.UU.	<u>Testeo</u> : 90%		
Altman (1968)	66 empresas	Industrial amplio	MDA	EE.UU.	<u>Testeo</u> : 94%	72%	48%
					<u>Testeo</u> : 79%	-	-
Deakin (1972)	158 empresas	Industrial amplio	Test de clasificación	EE.UU.	<u>Testeo</u> : 77%	96%	94%
	64 empresas		dicotómica MDA				
Ohlson (1980)	2.163 empresas	Industrial amplio	LOGIT	EE.UU.	<u>Testeo</u> : 96,1%	95,5%	
Zmijewski (1984)	420 empresas	Industrial amplio	PROBIT	EE.UU.	<u>Testeo</u> : 72%	63%	
Kluger y Shields (1989)	280 empresas	Manufacturero/Comercial	PROBIT	EE.UU.	<u>Testeo</u> : 82%	68%	74%
Hopwood, McKeown y Mutchler (1989)	500 empresas	Industrial amplio	LOGIT	EE.UU.	<u>Testeo</u> : 92%	85%	81%

Tabla 1.1. Principales estudios empíricos de predicción de quiebra
(Continuación)

AUTOR Y AÑO	MUESTRA	SECTOR	METODOLOGÍA	PAÍS	RESULTADOS		
					Años antes de quiebra		
					1	2	3
Odom y Sharda (1990)	129 empresas	Industrial amplio	RNA	EE.UU.	<u>Testeo</u> : 81,8%		
Tam (1991)	105 empresas	Industrial amplio	RNA	EE.UU.	<u>Testeo</u> : 78,6%		
Gilbert et al. (1990)	380 empresas	Industrial amplio	LOGIT	EE.UU.	<u>Testeo</u> : 62,5%		
Fletcher y Goss (1993)	32 empresas	Industrial amplio	LOGIT	EE.UU.	<u>Testeo</u> : 71,3%		
			RNA		<u>Testeo</u> : 80,5%	82,4%	75,0%
Altman (1993)	808 empresas	Industrial amplio	MDA	ITALIA	<u>Testeo</u> : 95,1%		
			RNA		<u>Testeo</u> : 95,3%		
Johnsen y Melicher (1994)	660 empresas	Industrial amplio	Modelo Binomial	EE.UU.	<u>Testeo</u> : 77,68%		
			Modelo Multinomial		<u>Testeo</u> : 94,64%		

Tabla 1.1. Principales estudios empíricos de predicción de quiebra
(Continuación)

AUTOR Y AÑO	MUESTRA	SECTOR	METODOLOGÍA	PAÍS	RESULTADOS		
					Años antes de quiebra		
					1	2	3
Varetto (1998)	420 empresas	Industrial amplio	GA	ITALIA	<u>Testeo</u> : 95,1%		
Laitinen y Laitinen (2000)	250 empresas	Industrial amplio	LOGIT	EE.UU.	<u>Testeo</u> : 77,9%		
Shumway (2001)	300 empresas	Industrial amplio	Hazard Model	EE.UU.	<u>Testeo</u> : 75%		
Bose y Pal (2006)	122 empresas	Industrial amplio	PMC	UK	<u>Testeo</u> : 83,75%		
			SVM		<u>Testeo</u> : 93,75%		
			MDA		<u>Testeo</u> : 80,0%		
Etemadi et al. (2009)	280 empresas	Industrial amplio	MDA	IRÁN	<u>Testeo</u> : 28,57%		
			SVM		<u>Testeo</u> : 21,43%		
			RNA		<u>Testeo</u> : 19,43%		
			GP		<u>Testeo</u> : 15,84%		
Yeh et al. (2010)	340 empresas	Industrial amplio	RST-SVM	MALASIA	<u>Testeo</u> : 87,26%		

Tabla 1.1. Principales estudios empíricos de predicción de quiebra (Continuación)					
AUTOR Y AÑO	MUESTRA	SECTOR	METODOLOGÍA	PAÍS	RESULTADOS
					Años antes de quiebra
					1 2 3
Chen et al. (2011)	10.366 empresas	Industrial amplio	SVM LOGIT		<u>Testeo</u> : 68,5% <u>Testeo</u> : 64,5%
Kwak et al. (2012)	195 empresas	Industrial amplio	MULTICRITERIO	COREA DEL SUR	<u>Testeo</u> : 88,70%
Zhou y Lai (2017)	350 empresas	Industrial amplio	AdaBoost	CHINA	<u>Testeo</u> : 87,85%

Tabla 1.2. Principales modelos globales de predicción de quiebra

AUTOR Y AÑO	MUESTRA	SECTOR	METODOLOGÍA	REGIÓN	RESULTADOS		
					Años antes de quiebra		
					1	2	3
Pindado et al. (2008)	3.833 empresas	Industrial amplio	LOGIT	G-7	<u>Testeo</u> : 87%		
Platt y Platt (2008)	4.688 empresas	Manufacturero/Industrial	LOGIT	EE.UU EUROPA ASIA	<u>Testeo</u> : 82,1%		
Zhou (2013)	188 empresas 74 empresas	Industrial amplio	MDA LOGIT DA RNA SVM	EE.UU. JAPÓN	<u>Testeo</u> : 77%	96%	
Korol (2013)	2.163 empresas	Industrial amplio	MDA DT RNA	AMÉRICA LATINA EUROPA CENTRAL	<u>Testeo</u> : 96,23%	88,68%	

Tabla 1.2. Principales modelos globales de predicción de quiebra (Continuación)							
AUTOR Y AÑO	MUESTRA	SECTOR	METODOLOGÍA	PAÍS	RESULTADOS		
					Años antes de quiebra		
					1	2	3
Tsai et al. (2014)	850 empresas	Industrial amplio	PMC SVM DT	ALEMANIA JAPÓN AUSTRALIA	<u>Testeo</u> : 88%		
Alaminos et al. (2016)	440 empresas	Empresas cotizadas	LOGIT	EUROPA ASIA EE.UU.	<u>Testeo</u> : 90%	84%	79%
Altman et al. (2017)	260.256 empresas	Industrial amplio	LOGIT	EUROPA COLOMBIA EE.UU. CHINA	<u>Testeo</u> : 75%		

1.4. FORMULACIÓN DE HIPÓTESIS

Del análisis efectuado a la literatura sobre predicción de quiebra se ha podido constatar la existencia de un patrón definido por lo que se refiere a la construcción de modelos regionales frente a modelos globales, siendo los primeros mucho más numerosos que los segundos. Sin embargo, han resultado escasas las referencias que se pronuncian a favor o en contra del uso de un tipo de modelo u otro (Bellovary et al., 2007). Tan solo el estudio de Alaminos et al. (2016) ha verificado la superioridad de los modelos globales.

Una explicación factible a esta carencia de un patrón delimitado en la literatura sobre la elaboración de un tipo determinado de modelos podría basarse en la frecuente utilización de muestras heterogéneas de compañías correspondientes a distintos países, o de muestras focalizadas en empresas que actúan en una actividad económica específica. Como afirman Platt y Platt (2008), este tipo de muestras pudiera ser la razón de la discrepancia entre los buenos resultados de clasificación ex-post y los comparativamente decepcionantes resultados de validación ex-ante, ya que los ratios utilizados como variables independientes pueden verse afectados por efectos propios del país o región en cuestión. En este sentido, Platt y Platt (1990) afirmaron que los países muestran diferencias con respecto al modelo exportador, productividad, factores de producción, costes laborales y organización sindical, estructura competitiva y modos de distribución, lo que da lugar a diferencias importantes en diversas medidas de salud financiera. Hay que apuntar que esta idea fue tomada en cuenta por Platt y Platt (2008), Tsai (2009) y Zhou (2013), quienes analizaron la influencia de los efectos propios de los países en los ratios financieros y su aplicación en la predicción de la quiebra empresarial. Todos ellos llegaron a la conclusión de que el modelo obtenido para una muestra

heterogénea de países tiene menos capacidad predictiva que el elaborado para un único país.

Korol (2013) encontró pocas similitudes entre los modelos elaborados para una muestra de empresas de América Latina y otra de Europa Central, ya que no obtuvo grandes diferencias significativas entre los porcentajes de acierto, lo que indicaba que era posible aplicarlos a una combinación de muestras. A partir de estas conclusiones, introdujo la idea de poder realizar un modelo global lo más amplio posible.

En un intento de superar estas dificultades, algunos autores adoptaron un enfoque orientado a una región geográfica amplia. Este enfoque se basa en el ajuste de los modelos globales introduciendo una variable que recoja la probabilidad inobservada de las regiones analizadas (Alaminos et al., 2016) o la inclusión de variables que recojan diferentes atributos de características propias de las regiones o países representados en la muestra (Altman et al., 2017). En ambos trabajos, los resultados de clasificación en los modelos, con los ratios incluidos, eran superiores a los obtenidos con modelos sin la inclusión de este tipo de variables, confirmando que este enfoque era de utilidad para modelos donde las empresas representan una extensa selección de países (Altman et al., 2017).

En definitiva, es posible que la ausencia de una conclusión de la superioridad de un modelo global sobre un modelo regional sea debida a que no se hayan podido comparar de forma homogénea un tipo de modelos y otros, dada la disparidad de metodologías, enfoques, bases de datos disponibles, periodos temporales y países utilizados. Además, la escasez de modelos globales no ha permitido una investigación en profundidad sobre qué métodos podrían incrementar la precisión de los

mismos. En consecuencia, este hueco existente en la literatura nos ha motivado a formular las siguientes hipótesis de investigación:

Hipótesis 1 (H_1): Las variables predictivas de quiebra en un modelo global construido con RNA son diferentes a las de los modelos regionales.

Hipótesis 2 (H_2): La introducción de variables regionales en un modelo global construido con RNA mejora su capacidad de predicción.

Hipótesis 3 (H_3): Un modelo global construido con RNA predice la quiebra correctamente en las diferentes regiones del mundo.

BIBLIOGRAFÍA CAPÍTULO 1

Agarwal, V. y Taffler, R. (2008). Comparing the performance of market based and accounting-based bankruptcy prediction models. *Journal of Banking and Finance*, 32, 1541–1551.

Aggarwal, R. y Goodell, J.W. (2014). Cross-national differences in access to finance: Influence of culture and institutional environments. *Research in International Business and Finance*, 31, 193-211.

Ahn H. y Kim, K. (2009). Bankruptcy prediction modelling with hybrid case-based reasoning and genetic algorithms approach. *Application Software Computing*, 9, 599–607

Alaka, H.A., Oyedele, L.O., Owolabi, H.A., Oyedele, A.A., Akinade, O.O., Bilal, M. y Ajayi, S.H. (2017). Critical factors for insolvency prediction: towards a theoretical model for the construction industry. *International Journal of Construction Management*, 17 (1), 25-49.

Alaminos, D., del Castillo, A. y Fernández, M.Á. (2016) A global model for bankruptcy prediction. *PLoS ONE* 11(11): e0166693.

Alfaro, E., García, N., Gámez, M. y Elizondo, D. (2008). Bankruptcy forecasting: An empirical comparison of AdaBoost and neural networks. *Decision Support Systems*, 45, 110-122.

Altman, E.I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance*, 23 (4), 589-609.

Altman, E.I. (1993). *Corporate Financial Distress and Bankruptcy*. 2nd ed. New York. John Wiley & Sons.

Altman, E.I., Iwanicz-Drozowska, M., Laitinen, E.K. y Suvas, A. (2017). Financial distress prediction in an International context: A review and empirical analysis of Altman's Z-Score model. *Journal of International Financial Management & Accounting*, 2, 131-171.

Anandarajan, M., Lee, P. y Anandarajan, A. (2001). Bankruptcy prediction of financially stressed firms: An examination of the predictive accuracy of artificial neural networks. *Intelligent Systems in Accounting, Finance and Management*, 10, 69-81.

Antunes, F., Ribeiro, B. y Pereira, F. (2017). Probabilistic modelling and visualization for bankruptcy prediction. *Applied Soft Computing*, 60, 831-843.

Arquero, J.L., Abad, M.C. y Jiménez, S.M. (2009). Procesos de fracaso empresarial en Pymes. Identificación y contrastación empírica. *Revista Internacional de la Pequeña y Mediana Empresa*, 2 (1), 64-77.

Atiya, A.F. (2001). Bankruptcy prediction for credit risk using neural network: A survey and new results. *IEEE Transactions on Neural Networks*, 12 (4), 929-935.

Back, B., Laitinen, T. y Sere, K. (1996). Neural networks and genetic algorithms for bankruptcy predictions. *Expert Systems with Applications*, 11, 407-413.

Balcaen, S. y Ooghe, H. (2006). 35 years of studies on business failure: an overview of the classic statistical methodologies and their related problems. *British Accounting Review*, 38, 63-93.

Baldwin, J. y Glezen, G.W. (1992). Bankruptcy prediction using quarterly financial statement data. *Journal of Accounting, Auditing and Finance*, 7, 269-289.

Bauer, J. and Agarwal, V. (2014). Are hazard models superior to traditional bankruptcy prediction approaches? A comprehensive test. *Journal of Banking and Finance*, 40, 432-442.

Barboza, F., Kimura, H. y Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83 (15), 405-417.

Bartoloni, E. y Baussola, M. (2014). Financial performance in manufacturing firms: A comparison between parametric and non-parametric approaches. *Business Economics*, 49 (1), 32-45.

Beaver, W.H. (1966). Financial ratios as predictors of failure. *Journal of Accounting Research*, 4, Empirical Research in Accounting, 71-111.

Bellovary J.L., Giacomino D.E. y Akers M.D. (2007) A review of bankruptcy prediction studies: 1930 to present. *Journal of Financial Education*, 33 (4), 3-41.

Berg, D. (2007). Bankruptcy prediction by generalized additive models. *Applied Stochastic Models in Business and Industry*, 23, 129-143.

Bernstein, L.A. (1984). *Análisis de Estados Financieros*. Ed. Deusto. Bilbao.

Betz, F., Oprica, S., Peltonen, T.A. y Sarlin, P. (2014). Predicting distress in European banks. *Journal of Banking & Finance*, 45, 225-241.

Bharath, S.T. y Shumway, T. (2008). Forecasting default with the Merton distance to default model," *Review of Financial Studies*, 21, 1339-1369.

Borrajo, M., Baroque, B., Corchado, E., Bajo, J. y Corchado, J. (2011). Hybrid neural intelligent system to predict business failure in small-to-medium-size enterprises. *International Journal Neural Systems*, 21 (4), 277-296.

Bose, I. y Pal, R. (2006). Predicting the survival or failure of click-and-mortar corporations: a knowledge Discovery approach. *European Journal of Operations Research*, 174, 959-982.

Brezigar-Masten, A. y Masten, I. (2012). CART-based selection of bankruptcy predictors for the logit model. *Expert Systems with Applications*, 39 (11), 10153-10159.

Bruneaua, C., de Bandtb, O. y. El Amria, W. (2012). Macroeconomic fluctuations and corporate financial fragility. *Journal of Financial Stability*, 8, 219-235.

Callejón, A.M., Casado, A.M., Fernández, M.A. y Peláez, J.I. (2013). A system of insolvency prediction for industrial companies using a financial alternative model with neural networks. *International Journal of Computational Intelligence Systems*, 4, 1-13.

Charalambous, C., Charitou, A. y Kaourou, F. (2000). Comparative analysis of artificial neural network models: Application in bankruptcy prediction. *Annals of Operations Research*, 99, 403-425.

Charitou, A., Neophytou, E. y Charalambous, C. (2004). Predicting corporate failure. Empirical evidence for the UK. *European Accounting Review*, 13 (3), 465-497.

Chaudhuri, A. y De, K. (2011). Fuzzy support vector machine for bankruptcy prediction. *Applied Soft Computing*, 11, 2472-2486.

Chauhan, N., Ravi, V., Chandra, D.K. (2009). Differential evolution trained wavelet neural networks: Application to bankruptcy prediction in banks. *Expert Systems with Applications*, 36 (4), 7659-7665.

Chen, H.L., Yang, B., Wang, G., Liu, J., Xu, X., Wang, S.J., y Liu, D.Y. (2011). A novel bankruptcy prediction model based on an adaptive fuzzy k-nearest neighbor method. *Knowledge-Based Systems*, 24 (8), 1348-1359.

Cho, S., Hong, H. y Ha, B.C. (2010). A hybrid approach based on the combination of variable selection using decision trees and case-based reasoning using the Mahalanobis distance: For bankruptcy prediction. *Expert Systems with Applications*, 4, 3482-3488.

Chou, C.H., Hsieh, S.C. y Qiu, C.J. (2017). Hybrid genetic algorithm and fuzzy clustering for bankruptcy prediction. *Applied Soft Computing*, 56, 298-316.

Chung, C.C., Chen, T.S., Lin, L.H. y Lin, Y.C. (2016). Bankruptcy prediction using cerebellar model neural networks. *International Journal of Fuzzy Systems*, 18 (2), 160-167.

Cielen, A., Ludo, P. y Vanhoof, K. (2004). Bankruptcy prediction using a data envelopment analysis. *European Journal of Operations Research*, 154, 526–532.

Coats, P.K., y Fant, L.F. (1993). Recognizing financial distress patterns using a neural network tool. *Financial Management*, 22, 3, 142-155.

Collins, R.A. (1980). An empirical comparison of bankruptcy prediction models. *Financial Management*, 9 (2), 52-57

Das, S.R., Hanouna P. y Sarin. A. (2009). Accounting-based versus market-based cross-sectional models of CDS spreads. *Journal of Banking and Finance*, 33, 719–730.

Deakin, E.B. (1972). A discriminant analysis of predictors of business failure. *Journal of Accounting Research*, 10 (1), 167-179.

Diamond, J. H. (1976). Pattern recognition and the detection of corporate failure. PhD. Dissertation, New York University.

Ding, Y., Song, X. y Zeng, Y. (2008). Forecasting financial condition of Chinese listed companies based on support vector machine. *Expert Systems with Applications*, 34, 3081–3089.

Dimitras, A., Zanakis, S. y Zopounidis, C. (1996). A survey of business failures with an emphasis on prediction methods and industrial applications. *European Journal of Operations Research*, 90, 487-513.

DuJardin, P. (2018). Failure pattern-based ensembles applied to bankruptcy forecasting. *Decision Support Systems*, 107, 64-77.

Edminster, R. (1972). An empirical test of financial ratio analysis for small business failure prediction. *Journal of Financial and Quantitative Analysis*, 7 (2), 1477-1493.

El Hennawy, R. y Morris, R. (1983). The significance of base year in developing failure prediction models. *Journal of Business Finance and Accounting*, 10 (2), 209-223.

El-Temtamy, O. (1995). Bankruptcy prediction: A comparative study on logit and neural networks. PhD Dissertation. Middle Tennessee University.

Etemadi, H., Rostamy, A. y Dehkordi, H. (2009). A genetic programming model for bankruptcy prediction: empirical evidence from Iran. *Expert Systems Applications*, 36 (2), 3199–3207.

Evans, J. y Borders, A.L. (2014). Strategically surviving bankruptcy during a global financial crisis: The importance of understanding chapter 15. *Journal of Business Research*, 67 (1), 2738-2742.

Figlewski, S., Frydman, H. y Liang, W. (2012). Modeling the effect of macroeconomic factors on corporate default and credit rating transitions. *International Review of Economics & Finance*, 21 (1), 87-105.

Fletcher, D. y Goss, E. (1993). Forecasting with neural networks. An application using bankruptcy data. *Information and Management*, 24, 159-167.

Friedman, H., Altman, E.I. y Kao, D. (1985). Introducing recursive partitioning for financial classification: the case of financial distress. *Journal of Finance*, 40, 269–291.

García, V. y Fernández, M.A. (1992). Solvencia y Rentabilidad de la Empresa Española. Instituto de Estudios Económicos. Madrid.

Gepp, A., Kumar, K. y Bhattacharya, S. (2010). Business failure prediction using decision trees. *Journal of Forecasting* 29, 536-555.

Gesel, T., Baesens, B., Suykens, J., Poel, D., Baestaens, D. y Willekens, M. (2006). Bayesian kernel based classification for financial distress detection. *European Journal of Operations Research*, 172, 979-1003.

Giordani, P., Jacobson, T., von Schedvin, E. y Villani, M. (2014). Taking the twists into account: Predicting firm bankruptcy risk with splines of financial ratios. *Journal of Financial and Quantitative Analysis*, 49, 1071-1099.

Guan, Q. (1993). Development of optimal network structures for back-propagation-trained neural networks. PhD dissertation. University of Nebraska.

Grüenberg, M. y Lukason, O. (2014). Predicting bankruptcy of manufacturing firms. *International Journal of Trade, Economics and Finance*, 5 (1), 93-97.

Hauser, R.P. y Booth, D. (2011). Predicting bankruptcy with robust logistic regression. *Journal of Data Science*, 9, 565-584.

Hensher, D. y Jones, S. (2007). Forecasting corporate bankruptcy: Optimizing the performance of the mixed logit model. *Abacus*, 43 (3), 241-364.

Hopwood, W., McKeown, J. y Mutchler, J. (1989). A test of the incremental explanatory power of opinions qualified for consistency and uncertainty. *The Accounting Review*, 44 (1), 28-48.

Hui, X. F., y Sun, J. (2006). An application of support vector machine to companies financial distress prediction. *Lecture Notes. Artificial Intelligent*, 3885, 274-282.

Hwang, R., K. F. Cheng, K.F. y Lee, J.C. (2007). A semiparametric method for predicting bankruptcy. *Journal of Forecasting*, 26, 317-342.

Izan, H. (1984). Corporate distress in Australia. *Journal of Banking and Finance*, 8, 303-320.

Jabeur, B.S. (2017). Bankruptcy prediction using Partial Least Squares Logistic Regression. *Journal of Retailing and Consumer Services*, 36 (C), 197-202.

Jo, H. y Han, I. (1996). Integration of case-based forecasting, neural network, and discriminant analysis for bankruptcy prediction. *Expert Systems with Applications*, 11, 415-422.

Jo, H. y Han, I. (1997). Bankruptcy prediction using casebased reasoning, neural networks, and discriminant analysis. *Expert Systems with Applications*, 13, 97-108.

Jones, S. Johnstone, D. y Wilson, R. (2017). Predicting Corporate Bankruptcy: An Evaluation of Alternative Statistical Frameworks. *Journal of Business Finance & Accounting*, 44 (1-2), 3-34.

Jones, S. y Hensher, D.A. (2007). Forecasting corporate bankruptcy: Optimizing the performance of the mixed logit model. *Abacus*, 43, 241-264.

Keener, M. (2013). Predicting the financial failure of retail companies in the United States. *Journal of Business and Economics Research*, 11 (8), 373-380.

Kim, H.J., Jo, N.O. y Shin, K.S. (2016). Optimization of cluster-based evolutionary undersampling for the artificial neural networks in corporate bankruptcy prediction. *Expert Systems with Applications*, 59 (15), 226-234

Kluger, B.D. y Shields, D. (1989). Auditor changes, information quality and bankruptcy prediction. *Managerial and Decision Economics*, 10 (4), 275-282.

Korol, T. (2013). Early warning models against bankruptcy risk for Central European and Latin American enterprises. *Economic Modelling*, 31, 22-30.

Kwak, W., Shi, Y. y Kou, G. (2011). Bankruptcy prediction for Korean firms after the 1997 financial crisis: using a multiple criteria linear programming data mining approach. *Review of Quantitative Finance and Accounting*, 38 (4), 441-453.

Laitinen, E.K. y Laitinen, T. (2000). Bankruptcy prediction application of the Taylor's expansion in logistic regression. *International Review of Financial Analysis*, 9, 327-349.

Laitinen, E.K. y Suvas, A. (2013). International applicability of corporate failure risk models based on financial statement information: comparisons across European countries. *Journal of Finance & Economics*, 1 (3), 1-26.

Lee, S. y Choi, W.S. (2013). A multi-industry bankruptcy prediction model using backpropagation neural network and multivariate discriminant analysis. *Expert Systems with Applications* 40, 2941-2946.

Li, H., Huang, H., Sun, J. y Lin, C. (2010). On sensitivity of case-based reasoning to optimal feature subsets in business failure prediction. *Expert System with Applications*, 37 (7), 4811-4821.

Li, H., Lee, Y., Zhou, Y. y Sun, J. (2011). The random subspace binary logit (RSBL) model for bankruptcy prediction. *Knowledge-Based Systems* 24, 1380-1388.

Lin, F., Yeh, C.C. y Lee, M.Y. (2011). The use of hybrid manifold learning and support vector machines in the prediction of business failure. *Knowledge-Based Systems*, 24, 95-101.

Liu, J. (2004) Macroeconomic determinants of corporate failures: evidence from the UK, *Applied Economics*, 36 (9), 939-945.

Lo, A.W. (1986). Logit versus discriminant analysis: a specification test and application to corporate bankruptcies. *Journal of Econometrics*, 31, 151-178.

Maghyereh, A.I. y Awartani, B. (2014). Bank distress prediction: Empirical evidence from the Gulf Cooperation Council countries. *Research in International Business and Finance*, 30, 126-147.

McKee, T.E. (2000). Developing a bankruptcy prediction model via rough sets theory. *Intelligent Systems in Accounting, Finance and Management*, 9, 159-173.

McKee, T.E. y Greenstein, M. (2000) Predicting bankruptcy using recursive partitioning and a realistically proportioned data set. *Journal of Forecasting*, 3, 219-230.

McKee, T.E. y Lensberg, T. (2002). Genetic programming and rough sets: A hybrid approach to bankruptcy classification. *European Journal of Operational Research*, 138, 436-451.

Mensah, Y.M. (1983). The Differential Bankruptcy Predictive Ability of Specific Price Level Adjustments: Some Empirical Evidence. *The Accounting Review*, 58 (2), 228-246.

Messier Jr., W. F. y Hansen, J. (1988). Inducing rules for expert system development: An example using default and bankruptcy data. *Management Science*, 34 (12), 1403-1415.

Meyer, P. y Pifer, H. (1970). Prediction of bank failures. *Journal of Finance*, 25 (4), 853-868.

Min, J.H. y Lee, Y. (2005). Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert Systems with Applications* 28, 603-614.

Mossman, C.E., Bell, G.G., Swartz, M.L. y Turtle, H. (1988). An empirical comparison of bankruptcy models. *The Financial Review*, 33 (2), 35-54

Mulford, C.W. y Comiskey, E.E. (2005). Creative cash-flow reporting. Uncovering Sustainable Financial Performance. John Wiley and Sons. New Jersey, 316 y ss.

Park, C.S. y Han, I. (2002). A case-based reasoning with the feature weights derived by analytic hierarchy process for bankruptcy prediction. *Expert Systems with Applications*, 23, 255–264.

Pendharkar, P.C. (2002). A potential use of data envelopment analysis for the inverse classification problem. *Omega*, 30 (3), 243-248.

Pindado, J., Rodrigues, L. y De la Torre, C. (2008). Estimating financial distress likelihood. *Journal of Business Research*, 61, 995-1003.

Platt, H.D. y Platt, M.B. (2008). Financial distress comparison across three global regions. *Journal of Risk and Financial Management*, 1 (1), 129-162.

Pompe, P. y Bilderbeek, J. (2005). Bankruptcy prediction: the influence of the year prior to failure selected for model building and the effects in a period of economic decline. *International Journal of Intelligent Systems in Accounting and Finance Management*, 13, 95-112.

Premachandra, I.M., Chen, Y. y Watson, J. (2011). DEA as a tool for predicting corporate failure and success: a case of bankruptcy assessment. *Omega*, 39 (6), 620–626.

Odom, M. y Sharda, R. (1990). A neural network model for bankruptcy prediction. Proceedings of the IEEE International Conference on Neural Networks, 2, 163-168.

Ohlson, J. (1980). Financial ratios and the probabilistic prediction of bankruptcy. Journal of Accounting Research, 18 (1), 109-131.

Ouenniche, J., Bouslah, K., Cabello, J.M. y Ruiz, F. (2017). A new classifier based on the reference point method with application in bankruptcy prediction. Journal of the Operational Research Society, 6, 1-8.

Ouenniche, J. y Tone, K. (2017). An out-of-sample evaluation framework for DEA with application in bankruptcy prediction. Annals of Operations Research, 254 (1-2), 235-250.

Oz, I.O. y Yelkency, T. (2017). A theoretical approach to financial distress prediction modeling. Managerial Finance, 43 (2), 212-230.

Rafiei, F.M., Manzari, S.M. y Bostanian, S. (2011). Financial health prediction models using artificial neural networks, genetic algorithm and multivariate discriminant analysis: Iranian evidence. Expert Systems with Applications, 38, 10210-10217.

Ravi, V. y Krishna, M. (2014). A new online data imputation method based on general regression auto associative neural network. Neurocomputing 138, 106-113.

Ravisankar, P. y V. Ravi (2010). Financial distress prediction in banks using Group Method of Data Handling neural network, counter propagation neural network and fuzzy ARTMAP. Knowledge-Based Systems, 23, 823-831.

Ravisankar, P., V. Ravi y Bose, I. (2010). Failure prediction of dotcom companies using neural network-genetic programming hybrids. *Information Sciences*, 180 (8), 1257-1267.

Ribeiro, B., Silva, C., Chen, N., Vieira, A. y das Neves, J.C. (2012). Enhanced default risk models with SVM+. *Expert Systems with Applications*, 39, 10140-10152.

Ryu, Y. y Yue, W. (2005). Firm bankruptcy prediction: experimental comparison of isotonic separation and other classification approaches. *IEEE Trans. Syst. Man Cybern- Part A: Systems Humans*, 21 (4), 265-276.

Santomero, A. y Vinso, J. (1977). Estimating the probability of failure for comercial banks and the banking system. *Journal of Banking and Finance*, 1(2), 185-205.

Sarkar, S. y Sriram, R.S. (2001). Bayesian models for early warning of bank failures. *Management Science*, 47 (11), 1457-1475.

Serrano-Cinca, C. y Gutiérrez-Nieto, B. (2013). Partial Least Square Discriminant Analysis for bankruptcy prediction. *Decision Support Systems*, 3, 1245-1255.

Simons, D. y Rolwes, F. (2009). Macroeconomic Default Modeling and Stress Testing. *International Journal of Central Banking*, 5 (3), 177-204.

Shin, K. y Lee, Y. (2002). A genetic algorithm application in bankruptcy prediction modeling. *Expert Systems with Applications* 23, 321-328.

Shin, K., Lee, T.L. y Kim, H. (2005). An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28, 127-135.

Shumway, T. (2001). Forecasting bankruptcy more accurately: A simple hazard model. *The Journal of Business*, 74, 101-124.

Smaraanda, C. (2014). Scoring functions and bankruptcy prediction models case study for Romanian companies. *Procedia Economics and Finance*, 10, 217-226.

Sun, J. y Li, H. (2008). Listed companies financial distress prediction based on weighted majority voting combination of multiple classifiers. *Expert Systems with Applications*, 35, 818-827.

Sun, J., Li, H., Huang, Q-H., y He, K.Y. (2014). Predicting financial distress and corporate failure: A review from the state-of-the-art definitions, modeling, sampling, and featuring approaches. *Knowledge-Based Systems*, 57, 41-56.

Sun, L. y Shenoy, P. (2007). Using Bayesian networks for bankruptcy prediction: Some methodological issues. *European Journal of Operations Research*, 180, 738-753.

Taffler, R.J. (1984). Empirical Models for the Monitoring of UK Corporations. *Journal of Banking and Finance*, 8, 199-227.

Tam, K. (1991). Neural network models and the prediction of bank bankruptcy. *Omega*, 19 (5), 429-445.

Tam, K. y Kiang, M. (1992). Managerial applications of neural networks: the case of bank failure prediction. *Management Science*, 38 (7), 926–947.

Theodossiou, P. (1993). Predicting shifts in the mean of a multivariate time series process: An application in predicting business failures. *Journal of the American Statistical Association*, 88 (422), 441-449.

Tinoco, M.H. y Wilson, N. (2013). Financial distress and bankruptcy prediction among listed companies using accounting, market and macroeconomic variables. *International Review of Financial Analysis*, 30, 394-419.

Tsai, C. (2009). Feature selection in bankruptcy prediction. *Knowledge-Based Systems*, 22 (2), 120-127.

Tsai, C., Hsu, Y. y Yen, D.C. (2014). A comparative study of classifier ensembles for bankruptcy prediction. *Applied Soft Computing*, 24, 977-984.

Tseng, F. y Hu, Y. (2010). Comparing four bankruptcy prediction models: Logit, quadratic interval logit, neural and fuzzy neural networks. *Expert Systems with Applications*, 37, 1846-1853.

Tsukuda, J. y Baba, S. (1994). Predicting Japanese corporate bankruptcy in terms of financial data using neural network. *Computers and Industrial Engineering*, 27, 445-448.

Varetto, F. (1998). Genetic algorithms applications in the analysis of insolvency risk. *Journal of Banking and Finance*, 22, 1421–1439.

Vavrina, J., Hampel, D. y Janová, J. (2013). New approaches for the financial distress classification in agribusiness. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, LXI (4), 1177-1182.

Vassalou, M. y Xing, Y., (2004). Default risk in equity returns. *The Journal of Finance*, 59(2), 831-868.

Wang, Y., Wang, S. y Lai, K.K. (2005). A new fuzzy support vector machine to evaluate credit risk. *IEEE Transactions on Fuzzy Systems*, 13 (6), 820-831.

Wasilewski, M. y Madra, M. (2008). An assessment of the agricultural enterprises' solvency with the usage of the Altman Model. *Acta Oeconomica et Informatica*, 2, 50-55.

Wu, W. (2011). Improving classification accuracy and causal knowledge for better credit decisions. *International Journal of Neural Systems*, 21 (4), 297-309.

Yang, Z. R., Platt, M. B. y Platt, H.D. (1999). Probabilistic neural networks in bankruptcy prediction. *Journal of Business Research*, 44, 67-74.

Yang, Z., You, W. y Ji, G. (2011). Using partial least squares and support vector machines for bankruptcy prediction. *Expert Systems with Applications*, 38, 8336-8342.

Yeh, C. C., Chi, D. J. y Hsu, M.F (2010). A hybrid approach of DEA, rough set and support vector machines for business failure prediction. *Expert Systems with Applications*, 37, 1535-1541.

Zavgren, C.V. (1985). Assessing the vulnerability to failure of American industrial firms. *Journal of Business and Accounting*, 12 (1), 19-45.

Zhang, G., Hu, M.Y., Patuwo, B.E. e Indro, D.C. (1999). Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis. *European Journal of Operations Research*, 116, 1, 16-33.

Zhou L (2013) Performance of corporate bankruptcy prediction models on imbalanced dataset: The effect of sampling methods. *Knowledge-Based Systems*, 41, 16-25.

Zhou, L. y Lai, K.K. (2017). AdaBoost models for corporate bankruptcy prediction with missing Data. *Computational Economics*, 50 (1), 69-94.

Zhou, L., Tam, K.P., y Fujita, H. (2016). Predicting the listing status of Chinese listed companies with multi-class classification models. *Information Sciences*, 328, 222-236.

Zmijewski, M.E. (1984). Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting Research*, 22, 59-81.

CAPÍTULO 2: MÉTODOS DE CLASIFICACIÓN

Dentro de las técnicas de análisis basadas en la inteligencia artificial destacan los métodos de asociación o analogías biológicas. Estas técnicas han tenido una enorme relevancia en los trabajos empíricos efectuados en las dos últimas décadas, impulsada por los buenos resultados obtenidos y que mejoraban, en muchas ocasiones, los de los modelos estadísticos existentes.

Un claro exponente de los métodos de analogías biológicas son RNA, que intentan ganar experiencia mediante simulaciones repetidas, es decir, organizarse mejor a sí mismas con el fin de maximizar la predicción o la clasificación. El modelo RNA se estructura a través de nodos (también llamadas neuronas) que se comportan como inputs, outputs o procesadores intermedios. Apoyado en un paradigma de aprendizaje, toma el primer caso, introduce sus datos, y a continuación el modelo hace lo mejor que puede una modificación de las ponderaciones para aumentar la precisión y seguir con el siguiente paso (Hair, Anderson, Tatham y Black, 1999). Este ciclo se repite para cada caso en la fase de entrenamiento, pudiendo evaluarse su capacidad predictiva externa con una muestra ajena a la utilizada en la calibración del modelo.

Las ventajas más importantes de los modelos RNA se encuentran en la solución de problemas independientemente de su complejidad, no necesitando, como sí les ocurren a otros modelos estadísticos, de una relación lineal. Por otro lado, como principal limitación, algunos académicos llaman a las RNA como “cajas negras”, en tanto que el investigador no puede controlar la estructura del modelo (en la forma en la que se conectan las neuronas entre sí). Además, tan solo permitiría obtener una matriz de clasificación o nivel de predicción, por lo que dificultaría la interpretación de los resultados en cuanto al mayor o menor impacto de cada una de las variables en el resultado final.

2.1. LAS REDES NEURONALES ARTIFICIALES (RNA)

Las RNA son modelos artificiales que intentan reproducir una de las características naturales de los seres humanos: la capacidad de memorizar y enlazar hechos. Por tanto, son modelos simplificados del cerebro humano.

El cerebro es capaz de procesar con celeridad ingentes cantidades de información procedentes de los sentidos, combinarla o compararla con la información almacenada y dar respuestas adecuadas incluso en situaciones nuevas. El factor más llamativo es su capacidad de aprender a representar la información necesaria para desarrollar tales habilidades de manera autónoma. De ahí que una de las principales inquietudes de los investigadores a lo largo del tiempo ha sido construir máquinas computacionales que sean capaces de realizar procesos con un nivel de inteligencia aceptable.

El cerebro humano posee en torno a 12 billones de células nerviosas o neuronas, que albergan la característica de poder comunicarse. Cada una de las neuronas tiene entre 5.600 y 60.000 conexiones dendríticas procedentes de otras neuronas, que están conectadas a la membrana de la neurona y conducen los impulsos enviados desde otras neuronas. Cada neurona cuenta con una salida denominada axón, y el contacto de éste con una dendrita se realiza mediante la sinapsis. El axón y las dendritas envían la señal en una única dirección. Se podría decir que el cerebro humano está compuesto de decenas de billones de neuronas interconectadas entre sí creando redes que desarrollan funciones específicas (Basheer y Hajmeer, 2000).

Las neuronas son eléctricamente operativas y entre ellas se relacionan a través de un flujo de corrientes eléctricas locales, que se

originan como respuesta a las diferencias de potencial entre las membranas celulares de las neuronas. Un impulso nervioso es una variación de voltaje que se produce en una zona determinada dentro de la membrana celular. Así, el impulso es transmitido a través del axón hasta llegar a la sinapsis, y aquí se origina la liberación de una sustancia química, llamada neurotransmisor, que se dispersa por el fluido que hay en el espacio sináptico. En el momento en el que este fluido toca el otro extremo envía la señal a la dendrita, que puede excitar a la neurona o inhibirla, es decir, sinapsis con peso positivo o peso negativo, respectivamente.

La señal originada por la neurona y enviada a lo largo del axón es de tipo eléctrico y la señal que se transmite entre los terminales axónicos de una neurona y las dendritas de la otra es de tipo químico. El conjunto de impulsos recibidos desde la sinapsis se suma o restan a la magnitud de las alteraciones del potencial de la membrana, y si consiguen llegar un valor cercano a 10 milivoltios, se disparan con una frecuencia dada o tasa de disparo, provocando uno o más impulsos que se reproducirán a lo largo del axón (Müller, Reinhardt y Strickland, 2012)

El aprendizaje se consigue a través de la fluctuación de la efectividad de las sinapsis, cambiando la presión que unas neuronas realizan sobre otras. La arquitectura, el tipo y la efectividad de las conexiones representan el estado de conocimiento de la red (Graupe, 2013)

2.1.1. COMPONENTES Y ORGANIZACIÓN DE UNA RED NEURONAL ARTIFICIAL

Las RNA son modelos computacionales que aparecieron tras experimentos realizados con el fin de obtener formalizaciones matemáticas sobre la estructura del cerebro. Replican la estructura del sistema nervioso conforme al funcionamiento del cerebro humano, basándose en el aprendizaje a partir de la experiencia, con la posterior extracción de conocimiento a partir de la misma (Flórez y Fernández, 2008). Su finalidad es la imitación del sistema nervioso central biológico gracias a procesadores artificiales, que además, puedan subsanar algunos errores humanos.

En un sistema neuronal biológico los elementos básicos son las neuronas, las cuales se organizan en redes agrupadas mediante una estructura de capas. En un sistema neuronal artificial se puede crear una estructura jerárquica análoga, de manera que una RNA puede proyectarse como una serie de procesadores elementales (neuronas artificiales), conectadas a otras neuronas, o bien a neuronas externas, con una salida que permite difundir las señales por diferentes vías.


Las neuronas están unidas entre sí por conexiones representadas por unos pesos sinápticos o ponderaciones, que muestran la importancia del enlace y que se acoplan conforme a un algoritmo de aprendizaje. El objetivo de este algoritmo es minimizar la función de coste definida en base al error en que se incurre comparando los datos obtenidos por la red con los datos reales. La salida de cada neurona es el resultado que proporciona una función, conocida como función de activación, hacia la suma de sus entradas transformadas por los pesos sinápticos.

El sistema neuronal está compuesto por diferentes estratos, y al mismo tiempo están formados por un conjunto de neuronas artificiales cuyas entradas proceden del mismo punto, y sus salidas conducen al mismo destino. Es esencial, pues, distinguir las diferentes clases de neuronas que participan en un sistema neuronal artificial:

- Neuronas de entrada: interceptan las señales desde el entorno. En el supuesto de estar en un estudio empírico de tipo predictivo estaría formado por los datos o variables aplicados para el modelo.
- Neuronas de salida: transmiten señales automáticamente fuera del sistema tras procesar los datos. Significan las salidas de la red.
- Neuronas ocultas: reciben estímulos y envían salidas, todo en el interior del sistema, sin tener contacto con el exterior. En estas neuronas se realiza el procesamiento principal de la información.

La figura 2.1 muestra la estructura típica de una RNA formada por una única capa oculta.

Figura 2.1. Arquitectura de Perceptrón Multicapa (PMC)



Fuente: Alaminos, del Castillo y Fernández (2019)

Flórez y Fernández (2008) señalan los atributos principales de las RNA:

- Estado de activación inicial: las neuronas de la red presentan un estado inicial determinado, de reposo o excitación, acorde a su valor de activación. Este valor puede ser continuo o discreto, limitado o ilimitado, dependiendo de la entrada recibida y del umbral de la neurona.
- Entradas a la neurona: las variables introducidas desde el exterior que se expongan a las neuronas de entrada pueden tener naturaleza binaria o continua, dependiendo del tipo de red elegida. Las neuronas de las capas superiores a las de entrada reciben como inputs las salidas producidas por las capas previas, acompañadas de un peso indicando su importancia relativa. Estas salidas pueden ser

también binarias o continuas, dependiendo del tipo de neurona considerada.

Las variables de entrada y salida de una RNA pueden ser binarias o continuas. En la variante PMC se pueden encontrar las dos clases señales, por ejemplo, para tareas de clasificación se utilizarían salidas binarias $\{0, +1\}$, y para una tarea de arreglo funcional se emplearía salidas continuas.

Según el tipo de salida, las neuronas toman nombres específicos (Müller y Reinhardt, 1990). A las neuronas estándar cuya salida únicamente admite los valores 0 ó 1 se les denomina neuronas de tipo de "McCulloch-Pitts", mientras que las que tienen salidas -1 ó +1 se denominan neuronas tipo "Ising", y si es posible adoptar diferentes valores discretos en la salida, como por ejemplo, un intervalo $\{-2, +2\}$ se dice que es una neurona de tipo "Potes".

Por su parte, la función de propagación de una RNA es una regla que marca el proceso a seguir para unir los valores de entrada a una unidad y los pesos de las conexiones que llegan a esa unidad. Esta función de propagación será fijada por los pesos w_{ij} , representativos de la influencia que ejerce la neurona i sobre la neurona j . Se pueden establecer tres valores separados: en primer lugar, un valor positivo, lo cual significará que la relación entre las neuronas i y j es excitadora, es decir, si la neurona i está activada la neurona j interceptará una señal de que debe de activarla. Pero si este peso es negativo supondrá que la sinapsis es inhibidora, por lo que, si el elemento i está activo, transmitirá una señal a la neurona j que tendrá que desactivar a ésta. Por último, en el escenario de que el peso sea $w_{ij}=0$, se estima que no existe conexión entre ambas neuronas.

El peso sináptico w_{ij} establece la magnitud de la conexión entre la neurona pre-sináptica j y la post-sináptica i . Además, pueden manifestarse diferentes tipos de relaciones entre las neuronas:

- Conexiones intracapa o laterales: se originan entre las neuronas de una misma capa.
- Conexiones intercapa: se crean entre neuronas de diferentes capas.
- Conexiones realimentadas: relaciones con sentido contrario al de entrada-salida (se mostrarían de derecha a izquierda).
- Conexiones autorrecurrentes: las de realimentación de una neurona consigo misma.

La función de propagación más usual es la de naturaleza lineal, fundamentada en la suma ponderada de las entradas con los pesos sinápticos, expresada de la siguiente forma:

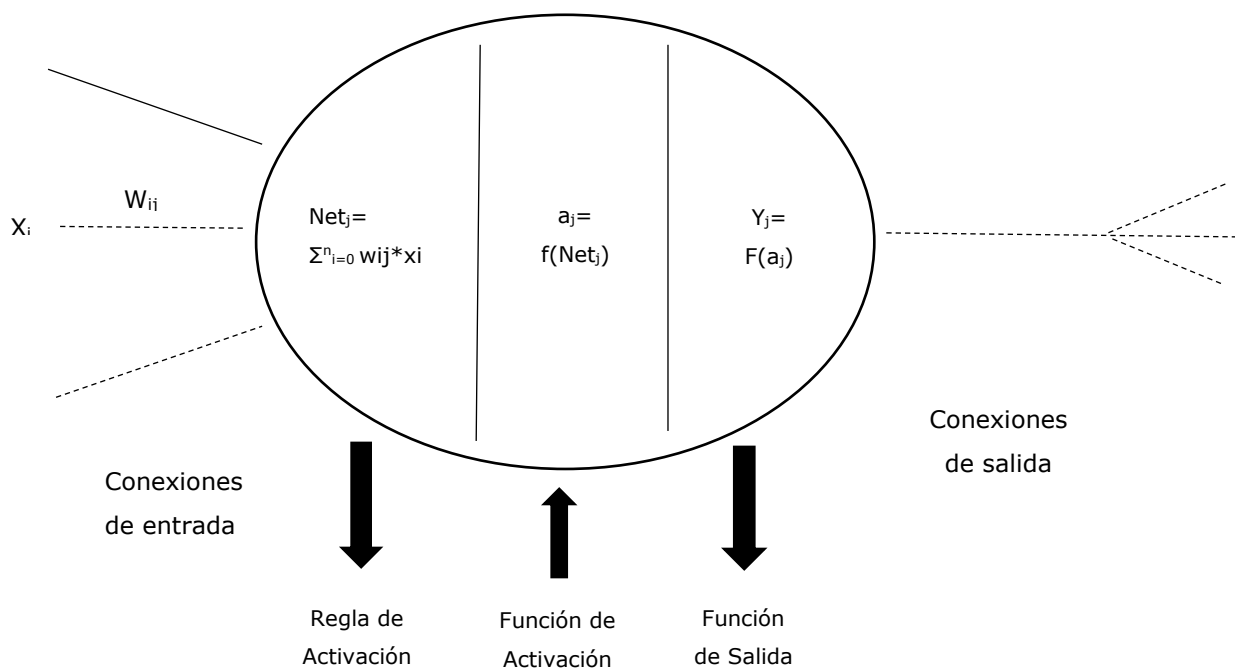
$$Net_j = \sum_{i=0}^N w_{ij}(t) * x_i(t) \quad [2.1]$$

Existe otra modalidad de función de propagación, denominada función de base radial, la cual es una función no lineal y admite la posibilidad de interpretar la aportación de cada unidad en el desarrollo global de la red, ya que cada unidad es activa únicamente en una zona limitada del espacio de entrada y representa la distancia a un patrón de referencia dado (Zemouri et al., 2003).

De otro lado, la denominada función de activación es la que une la entrada completa a la j -ésima neurona post-sináptica (Net_j),

consiguiendo mediante los estímulos y pesos recibidos generar un nuevo estado de activación. La función de activación más usual es la sigmoidea, si bien existen otras tales como la función lineal, la función escalón, la función mixta, la función gaussiana y la función sinusoidal. La figura 2.2 muestra un modelo básico de neurona artificial.

Figura 2.2. Modelo Básico de Neurona Artificial



Fuente: Russel y Norvig (2004).

Finalmente, la denominada función de salida hace alusión a que toda neurona U_j está relacionada con una función de salida F que modifica el estado actual de activación $a_j = f(Net_j(t))$ en una señal de salida $y_j(t)$:

$$y_j(t) = F(a_j) = F(f(\text{Net}_j(t))) \quad [2.2]$$

Es común que la función de salida sea la misma función que la de identidad $F(x)=x$, por lo que el estado de activación de la neurona se considera su salida final. Esta situación se origina en redes tales como PMC y red Adaline. La clase de salida deseada será la que defina la función de transferencia, y se lleva a cabo en las neuronas de la última capa de la red.

Como veremos más adelante, las dos arquitecturas de RNA más importantes son las acíclicas o redes con alimentación-hacia-delante y cíclicas o redes recurrentes. La primera representaría una función de sus entradas actuales, y su único estado interno es el de sus pesos. La red recurrente, por el contrario, admite que sus salidas sustenten sus entradas, ya que la información puede volver a puntos por los que ya había pasado, y se aceptan las conexiones intra-capa (llamadas laterales), admitiendo conexiones de una unidad consigo misma.

Por lo general, las RNA con alimentación hacia delante se estructuran en capas, donde la información fluye de manera unidireccional desde la capa de entrada a las capas de ocultas, y de éstas a la capa de salida, por lo que cada unidad tiene entradas únicamente en las unidades de la capa que le precede. No se admiten relaciones intra-capa, y las conexiones pueden ser totales cuando cada unidad se conecta con todas las unidades de la capa siguiente, o parciales, cuando una unidad se conecta con un conjunto determinado de las capas de la unidad posterior, siguiendo algún comportamiento aleatorio o pseudo-aleatorio (Zemouri et al., 2003).

2.1.2. ARQUITECTURA DE REDES NEURONALES

La arquitectura o estructura de RNA hace mención a la organización y distribución de las neuronas en la red formando capas o conjuntos agrupados de neuronas más o menos distanciadas de la entrada y salida (Hilera y Martínez, 1995). Dependiendo del número de capas, de la categoría de conexión entre neuronas, de la clase de respuesta, de la naturaleza de los datos de entrada y salida o del algoritmo de aprendizaje, aparecerán numerosas estructuras RNA diferentes (Bernardos y Vosniakos, 2007).

Dependiendo del número de capas se suele diferenciar entre RNA con una única capa o nivel de neuronas (monocapas), y RNA con múltiples capas (multicapas). Las monocapa son las más simples debido a que tienen una capa de neuronas que impulsan las entradas a una capa de salida en la que se efectúan varias estimaciones, siendo ésta la única que se considera, porque en la capa de entrada no se lleva a cabo cálculo alguno. Se emplean habitualmente para tareas de autoasociación. Ejemplos de RNA monocapa son la red Hopfield y la red Brain-State-in-a-box.

En las multicapas se encuentran una serie de capas intermedias entre la entrada y la salida (capas ocultas). Y puede suceder que estén total o parcialmente relacionadas.

Dependiendo de la clase de conexión o procedencia de las señales que recibe a la entrada y el destino de la señal de salida existen redes no recurrentes o alimentadas hacia delante (también llamadas feedforward), y redes recurrentes o feedback. En las no recurrentes, las neuronas de cada nivel sólo están relacionadas con las neuronas de los niveles posteriores, por lo que los datos se difunden hacia delante (las señales externas se introducen por la capa de entrada, transitan por

las capas ocultas y llegan hasta la capa de salida, y no hay conexión hacia las capas anteriores, y por lo habitual, tampoco hacia su propia entrada). Algunos ejemplos de redes no recurrentes son el PMC, Adaline, Madaline, Linear Adaptive Memory (Lam), Drive-Reinforcement, y Backpropagation.

Por su parte, las redes recurrentes son aquellas en las que los datos transitan tanto hacia delante como hacia atrás. Al presentar realimentación, la información se propaga hacia adelante y hacia atrás como si fuese un sistema dinámico en el que la respuesta de la red se equilibrará tras un determinado número de iteraciones, convergiendo a un estado equilibrado. Las neuronas aceptan cualquier conexión: conectadas con neuronas de niveles previos, de niveles posteriores, con neuronas de su mismo nivel (conexiones laterales) o incluso con ellas mismas (conexión autorrecurrente). Las redes más usuales suelen ser bicapas (dos capas), como es el caso de la red ART (Adaptive Resonante Theory), la red BAM (Bidirectional Associative Memory) y la Neocognitron.

Dependiendo del grado de conexión, podemos diferenciar también entre RNA completamente conectadas y parcialmente conectadas. En el caso de las completamente conectadas, todas las neuronas de una capa están conectadas con las de la capa siguiente (redes no recurrentes) o con las de la anterior (redes recurrentes). Las redes parcialmente conectadas no tienen conectadas completamente las neuronas entre las distintas capas.

De todas las clases de RNA, suelen ser bastantes importantes las no realimentadas y de aprendizaje supervisado y, dentro de éstas, los casos del Perceptrón Simple, Adelina y PMC. El algoritmo de aprendizaje llamado back-propagation (retropropagación), como se

expondrá más adelante, se emplea en este último modelo, que es el más utilizado para las aplicaciones de RNA.

2.1.3. MODOS DE OPERACIÓN: APRENDIZAJE Y RECUERDO

Las RNA han sido creadas para mostrar características idénticas a las del funcionamiento del cerebro humano. La capacidad de aprender es una de las peculiaridades de RNA y que la diferencian de la programación convencional. Tienen una gran capacidad de aprender desde la experiencia, de asemejar los casos anteriores a nuevos casos, y de extraer características esenciales a partir de entradas que representan información intrascendente.

Por otro lado, RNA no alberga ningún tipo de conocimiento útil, lo que provoca la necesidad de entrenarla, o, dicho de otra manera, enseñarla para que tenga capacidad de ejecutar una determinada tarea. Se diferencian dos modos de operación en RNA: el modo aprendizaje o entrenamiento y el modo recuerdo o ejecución.

La definición de aprendizaje fue construida previamente a la aparición de RNA, y se puede utilizar para explicar el funcionamiento de estos algoritmos. Podría ser la alteración del comportamiento provocado por la interacción con el entorno, y como resultado de experiencias que conducen al desarrollo de nuevos modelos de respuesta a estímulos externos (Hilera y Martínez, 1995). Una característica esencial de RNA es, por tanto, que son sistemas entrenables, con capacidad de aprender mediante un conjunto de patrones de entrenamiento.

Durante el proceso de aprendizaje se fijan los parámetros libres de la red a través de un proceso de interacción con el entorno que la

envuelve, y es tanto de naturaleza secuencial como adaptativo. De esta forma, RNA consigue conocimiento de manera continua gracias a la acumulación de experiencias acaecidas, similar al proceso de aprendizaje del cerebro humano, en lo que se refiere a considerar los errores anteriores (Kuan y White, 1994).

A partir de esta estructura primitiva, RNA deberá entrenar para alcanzar el objetivo perseguido. Al construir un modelo RNA se especifica una determinada arquitectura de red en la que los pesos sinápticos iniciales son nulos o aleatorios. Para que la red resulte operativa es necesario entrenarla, lo que constituye el modo aprendizaje. El aprendizaje tradicional cambia los pesos sinápticos como reacción a una información de entrada o regla de entrenamiento, alcanzada optimizando una función de error que estima la eficacia de la red. Se suelen contemplar dos clases de reglas: las que responden a un aprendizaje supervisado y las que lo hacen a un aprendizaje no supervisado. Habitualmente es un proceso iterativo, que actualiza los pesos continuamente hasta que RNA consigue el rendimiento óptimo (Haykin, 1999).

Una de las características más importantes en la creación de RNA es la capacidad de la red para generalizar a través de ejemplos, esquivando la simple memorización de patrones de aprendizaje, y facilitando una respuesta correcta ante individuos no introducidos durante la etapa de entrenamiento (Martín del Brio y Sanz, 2001). En este aspecto, es fundamental que se tenga en cuenta tanto el error incurrido en la predicción de la muestra durante la etapa de entrenamiento como también el error de generalización, este último más importante para obtener unos resultados fiables. Por lo general, el error de predicción o de clasificación irá decreciendo durante la fase de entrenamiento. Y con el propósito de no incurrir en un sobreajuste por parte la red, sería necesario parar el entrenamiento siempre que

al examinarle se constate un aumento del error de predicción o clasificación. Para poder acometer esta evaluación es necesaria una muestra externa, ajena a los datos aplicando durante el entrenamiento. Esto lleva a dividir el conjunto de datos en dos submuestras: un set de datos dedicados al entrenamiento de la red, que permite establecer los parámetros de la misma (a la que se llama muestra de entrenamiento); y en segundo lugar, un conjunto de datos que se empleará para ir evaluando el error de la red en la etapa de entrenamiento, con la finalidad de determinar el momento en el que se deja de entrenar la red (que se denomina muestra de validación). Esta muestra de validación (diferente de la muestra de testeo), facilitará evitar el “sobre-entrenamiento” o “sobre-aprendizaje” de la red, optimizando la capacidad de generalización de ésta.

Está comprobado que cuando se consiguen reducidos errores en la muestra de entrenamiento, el error de generalización se incrementa. El punto óptimo será aquel que minimice el error en el testeo, aunque no sea el punto donde se alcance el menor error de aprendizaje.

2.1.4. ALGORITMO DE RETROPROPAGACIÓN

En el entrenamiento de RNA se usan un algoritmo que determinan los pesos sinápticos de las conexiones entre las neuronas. De todos los algoritmos creados, el más recurrente es el algoritmo de retropropagación (backpropagation) o propagación hacia atrás, por ser de implementación simple, versatilidad y alta eficiencia computacional (Yao et al., 2000).

Su nombre procede de la propagación del error hacia atrás, desde la capa de salida hacia la capa de entrada, pasando por las capas ocultas intermedias y ajustando los pesos de las conexiones con el

objetivo de reducir el error (Han, 2002). Tras terminar el proceso de entrenamiento y estimando los pesos de RNA, es de importancia verificar la calidad del modelo, y para ello se revisan los errores entre los valores de salida deseados y los alcanzados.

Se puede encontrar una amplia multitud de variantes del algoritmo de entrenamiento (Teixeira, 2004). El término de inercia (Algoritmo "Gradient descent with momentum backpropagation-traingdm"), en el que la red, además de responder al gradiente local, permite que la red omita variaciones mínimas en la superficie del error (low-pass-filter). Además, ratio de aprendizaje variable (Algoritmo "Gradient descent with adaptive learning rate backpropagation-traingda"), que por regla general es de carácter adaptativo, persigue que la tasa de aprendizaje sea lo más alta posible para asegurar la estabilidad del algoritmo. Finalmente, el Resilient backpropagation (Algoritmo "Resilient backpropagation-trainrp"), que se sitúa en el tipo de redes multicapa, utiliza una función hiperbólica en la capa oculta. Ésta compacta una serie ilimitada de valores de entrada en una salida limitada y tiene una derivada prácticamente nula en los extremos. Emplea el signo de las derivadas para calcular el sentido de la actualización de los pesos, sin considerar el valor absoluto de las derivadas en dicha actualización.

En conclusión, para cada clase de evento en análisis será más aconsejable un modelo de algoritmo. Algunas veces será mejor un algoritmo que funcione más lento, considerando la salida que se desea alcanzar. En otras, se necesitará rapidez.

2.2. EL PERCEPTRON MULTICAPA (PMC)

2.2.1. ESTRUCTURA DEL PMC

El denominado PMC es el modelo de RNA supervisada más empleado en la literatura, lo que anima a una especial mención.

Es una red de alimentación hacia delante que estaría compuesta por una capa de unidades (neuronas) de entrada (sensores), otra capa de salida, y un número determinado de capas intermedias, llamadas capas ocultas en tanto que no tienen conexiones con el exterior. Cada sensor de entrada estaría conectado con las unidades de la segunda capa, y éstas a su vez con las de la tercera capa, y así sucesivamente (gráfico 4.6.). La red tendrá como objetivo establecer una correspondencia entre un conjunto de entrada y un conjunto de salidas deseadas.

El PMC apareció en los años 80 a partir de la limitación principal del Perceptrón Simple, el cual precisaría de la necesidad de aprender de funciones linealmente separables por no disponer de un algoritmo que permitiera obtener y actualizar los pesos intermedios del sistema (Minsky y Papert 1969).

La solución a esta adversidad vino precisada por la incorporación de capas ocultas de neuronas, entre la capa de entrada y la capa de salida. Las estructuras de un Perceptrón Simple y de un PMC vienen a coincidir, con la única excepción de que PMC cuenta con una o varias capas ocultas.

Mediante la teoría del “Teorema de Kolmogorov” (Kolmogorov, 1957; Netch-Nielsen, 1987, 1990) se comprobó que una arquitectura de características parecidas al PMC y con una única capa oculta

resultaba ser un proxy universal de funciones, sin la necesidad de requerir arquitecturas de redes más complejas. Nuñez de Castro y Von Zuben (1998) demostraron que el aprendizaje en PMC conformaba un caso especial de aproximación funcional, donde no existe ninguna asunción acerca del modelo subyacente a los datos analizados. El proceso de aprendizaje supone encontrar una función que represente correctamente los patrones de aprendizaje además de llevar a cabo un proceso de generalización que permita tratar de forma eficiente a individuos no analizados durante el aprendizaje (Flórez y Fernández, 2008). Para ello se procede al ajuste de pesos W a partir de la información procedente del conjunto muestral, considerando que tanto la arquitectura como las conexiones de la red son conocidas, siendo el objetivo obtener aquellos pesos que minimicen el error de aprendizaje.


Dado, pues, un conjunto de pares de patrones de aprendizaje $\{(x_1, y_1), (x_2, y_2) \dots (x_p, y_p)\}$ y una función de error $\varepsilon(W, X, Y)$, el proceso de entrenamiento significa la búsqueda del conjunto de pesos que minimiza el error de aprendizaje $E(W)$ (Shang y Wah, 1996):

$$\min_W E(W) = \min_W \sum_{i=1}^p \varepsilon(W, x_i, y_i) \quad [2.3]$$

La mayoría de los modelos analíticos empleados para minimizar la función de error aplican métodos que exigen la evaluación del gradiente local de la función $E(W)$, pudiendo considerarse también técnicas basadas en derivadas de segundo orden (Flórez y Fernández 2008).

Si bien se trata de un área en constante desarrollo, los algoritmos de aprendizaje más habituales para las redes tipo PMC son el algoritmo de retropropagación de errores ("backpropagation"), los algoritmos basados en el gradiente conjugado y los modelos quasi-Newton.

Figura 2.4. Arquitectura de una red PMC con una capa oculta.



Fuente: Flórez y Fernández (2008) por adaptación de Martín del Brio y Sanz (2001).

2.2.2. ANÁLISIS DE SENSIBILIDAD

El análisis de sensibilidad es una técnica de las más recurridas para la interpretación de los pesos o parámetros de un modelo RNA (Hashem, 1992; Lisbon, Mehridehnavi y Martin., 1994). El objetivo que se busca es conocer en qué medida las oscilaciones en los valores o parámetros de entrada influyen en los resultados de salida del mismo. Y es justamente a través del análisis de estas variaciones por lo que es posible determinar la importancia de cada variable, ya que cada una de ellas tiene una representación proporcional en el modelo.

Haciendo uso de una metodología computacional como es el caso de PMC, se determina y calcula el grado de importancia que cada variable tiene dentro del modelo. Para llevar a cabo este análisis se recurre a una función creciente de la diferencia entre la salida esperada

o conocida de la red, denominado también valor objetivo, y la salida de ésta con el valor modificado de la variable. En general, para cualquier tipo de modelo, la fórmula empleada en el análisis sería una derivada de la forma expresada en [2.4].

$$Sx_i = \frac{\delta(Modelo)}{\delta X_i} \quad [2.4]$$

donde Sx_i constituye el valor de sensibilidad de la variable X_i . Este valor de sensibilidad corresponde proporcionalmente al peso que una variable determinada tiene dentro del modelo, lo cual sería equivalente al coeficiente de la variable en un modelo de tipo lineal (Serrano et al., 2009).

La técnica del análisis de sensibilidad (Chong, 2013) se basa en tomar la totalidad de los datos y segmentarlos en grupos por cada clase de clasificación. Cada grupo de datos se procesa en la RNA creada tantas veces como variables del modelo existan. En cada momento se altera el valor de una de las variables ubicándola con valor cero. Las respuestas de la red son examinadas con relación a los valores objetivos o valores de clasificación ya conocidos, a través de la expresión [2.5].

$$Sx_i = \sum_{j=1}^n (\Phi x_{ij}(0) - \Phi x_{ij})^2 \quad [2.5]$$

donde $\Phi x_{ij}(0)$ es el valor de la salida de la red cuando la variable X_{ij} vale cero, Φx_{ij} es el valor objetivo o de clasificación ya conocido, X_i es la variable cuya importancia se desea establecer y Sx_i es el valor de sensibilidad de la variable. El valor de i se distribuye desde 1 hasta el

total de variables, y el de j va desde 1 hasta el total de datos del conjunto muestral.

Obtenido un valor de sensibilidad parcial de cada variable por cada uno de los grupos, se estima el porcentaje correspondiente para cada variable con relación al grupo, y luego se aplica un factor de proporción de acuerdo con el tamaño de los datos del grupo en relación con el total de la muestra. Finalmente, se suman todos los porcentajes parciales de cada grupo para cada variable obteniéndose un porcentaje total de las mismas. Este porcentaje total alcanzado es considerado proporcional al valor de sensibilidad y equivalente a la importancia que cada variable tiene dentro del modelo estudiado.

2.3. CRITERIOS PARA LA SELECCIÓN DE MODELOS

La construcción de modelos estadísticos o computacionales surge de la necesidad de explicar y predecir un fenómeno real que depende de variables. Generalmente, cuando se trata de modelar este comportamiento, y se plantean varios modelos alternativos, surge el problema de qué modelo seleccionar dentro del conjunto de modelos que se hayan estimado. La selección del mejor modelo es, a menudo, una elección entre teorías en competencia y se basa en resultados empíricos obtenidos a partir de datos de la muestra. En este capítulo trataremos los dos métodos empleados en el presente trabajo de investigación: el método de validación cruzada y los criterios basados en la información.

2.3.1. MÉTODO DE VALIDACIÓN CRUZADA

La validación cruzada (CV) es una de las técnicas más empleadas para valorar la precisión o acierto de un modelo (validación de resultados) (Allen, 1974; Stone, 1974; Geisser, 1975). Fundamentalmente, se basa en la división de los datos. Una parte de ellos se usa para la creación de cada modelo, y el resto de los datos se emplea para cuantificar la precisión de los modelos predictivos mediante la evaluación de los errores de validación, seleccionándose el modelo con la mejor precisión global (Zhang y Yan, 2015). En este sentido, CV se ha usado extensamente en la minería de datos para la selección de modelos, o bien como selección del proceso de modelización (Hastie, Tibshirani y Friedman, 2009).

Un tema esencial en la utilización de CV para la discriminación de modelos es la selección del ratio de división de datos o el tamaño del conjunto de validación. En el presente trabajo, se efectúa una división del 70% de la muestra para el conjunto de entrenamiento y un 30% para la validación.

De las distintas variantes de CV (validación cruzada dejando uno fuera, de retención y de k-iteraciones), el tipo de k-iteraciones es una de las más empleadas (Cheng y Pecht, 2012). Dentro de la técnica de k-iteraciones, el conjunto de datos se divide en k subconjuntos de igual tamaño. A continuación, se realiza un proceso iterativo. En cada iteración, se selecciona un subconjunto diferente como datos de validación para calcular la precisión del modelo, y los restantes k-1 subconjuntos se usan como prueba de entrenamiento (para entrenar el modelo). Para la selección más común de 10 iteraciones (10-CV), nueve subconjuntos se utilizan como pruebas de entrenamiento y el subconjunto restante para la prueba de testeo. Este proceso se repite hasta que cada uno de los diez subconjuntos se examinan. El 10-CV

lleva a cabo, de forma independiente, diez divisiones distintas del conjunto de datos.

2.3.2. CRITERIOS BASADOS EN LA INFORMACIÓN

Los procedimientos basados en validación de hipótesis no castigan el exceso de parámetros debido a que, habitualmente, se selecciona un modelo saturado como referencia. En cambio, los criterios de selección de modelos basados en la Teoría de la Información equilibran el ajuste del modelo y su complejidad. Estos criterios toman la forma de una función de verosimilitud penalizada, que es el valor negativo del logaritmo de la función de verosimilitud, más un término de penalización que aumenta conforme lo hace el número de parámetros.

Entre los diversos métodos o criterios de selección de modelos basados en la Teoría de la Información pueden distinguirse el criterio de información de Akaike (1973), el bayesiano de Schwarz (1978) y el de Hannan-Quinn (1979).

2.3.2.1. El criterio de Akaike (AIC)

El criterio básico de entre los que se fundamentan en la información es el criterio de Akaike, que fue inicialmente desarrollado para evaluar series temporales.

En el caso general, el criterio de Akaike viene expresado como:

$$AIC = 2k - 2Ln(L) \quad [2.6]$$

donde:

k = número de parámetros.

L = Máximo valor de la función de verosimilitud del modelo estimado.

La idea elemental subyacente al empleo del criterio de Akaike para la selección de modelos es la maximización del logaritmo de la función de verosimilitud esperada de un modelo concreto.

El segundo término de la expresión [2.6] puede ser interpretado como una medida de la bondad de ajuste, en tanto que el primer término es una penalización creciente conforme aumenta el número de parámetros.

Como indica Takane (1987), el criterio de Akaike destaca la bondad del modelo, aunque no intenta encontrar el modelo correcto. Que un modelo sea el que mejor encaja con los datos no implica que el modelo será el acertado. En realidad, significa que el modelo es el mejor de entre los modelos posibles, en la manera en la que ofrece una aproximación más inmediata al modelo correcto.

El modelo que mejor se ajusta a los datos, podría cambiar en función del tamaño muestral, dado que, con un tamaño muestral mayor, los parámetros de un modelo pueden ser estimados de manera más fiable. Como puede observarse en [2.6], el término de penalización $2k$ no está supeditado al tamaño muestral de la población considerada. Esto conduce al hecho de que un mismo número de

parámetros puede ser seleccionado mediante el criterio de Akaike, tanto para muestras pequeñas como para muestras grandes.

2.3.2.2. El criterio de Schwarz (BIC)

Schwarz (1978) planteó que el criterio de Akaike podría no ser asintóticamente justificable y propuso un criterio de información alternativo mediante un enfoque bayesiano. Con este criterio se penaliza el número de parámetros con $\ln(n)$ en lugar de con 2. Así, la expresión del criterio de Schwarz quedaría como sigue:

$$BIC = -2\ln(L) + \ln(n) \times k \quad [2.7]$$

donde:

k = número de parámetros.

L = máximo valor de la función de verosimilitud del modelo estimado.

n = número de observaciones

De esta manera, este criterio pondera la desviación del modelo, medida por $-2\ln(L)$, con el número de parámetros. Si se incorporan más parámetros en el modelo mejorará el ajuste, con lo que disminuirá la desviación y este efecto será compensado por el aumento del número de observaciones.

Este criterio, a diferencia del criterio de Akaike, tiene en cuenta el número de observaciones en el término de penalización, resultando menos favorable a la incorporación de parámetros. Otra diferencia es que BIC trata de elegir el modelo correcto, con máxima verosimilitud a posteriori, y es un criterio consistente. Por el contrario, AIC no intenta

seleccionar el modelo correcto, ya que acepta que el modelo verdadero puede no estar entre los estimados, e intenta obtener el modelo que arroje mejores predicciones entre los existentes. (Peña, 2002).

Puede comprobarse que, suponiendo que el modelo correcto puede aproximarse arbitrariamente bien con los estimados al incrementar el tamaño muestral, el criterio AIC es eficiente, seleccionando el modelo que proporciona, en término medio, mejores predicciones. Sin embargo, en muestras pequeñas o medianas, el criterio AIC tiende a seleccionar modelos con más parámetros de los necesarios (Peña, 2002).

En definitiva, el criterio BIC asume que el modelo real está incluido en el grupo de modelos candidatos y cuantifica el nivel de certeza de que un cierto modelo sea el verdadero modelo generador de los datos.

2.3.2.3. El criterio de Hannan-Quinn (HQC)

El criterio de Hannan y Quinn puede ser interpretado como una variante del criterio de Schwarz, con una leve penalización de la importancia del tamaño muestral. Hannan y Quinn (1979) plantearon este criterio de información, originalmente sugerido para seleccionar el orden de una autoregresión, en la siguiente forma:

$$HQC = -2\ln(L) + 2\ln[\ln(n)] \times k \quad [2.8]$$

donde:

k = número de parámetros.

L = máximo valor de la función de verosimilitud del modelo estimado.

n = número de observaciones.

Del mismo modo que en los criterios AIC y BIC, se selecciona el modelo que minimice el valor de HQC.

BIBLIOGRAFÍA CAPÍTULO 2

Akaike, H. (1973). Information theory and an extension of the maximum likelihood principle. In B. N. Petrov and F. Csaki (Eds.), Second international symposium on information theory, 267-281.

Alaminos, D., del Castillo, A., y Fernández, M.Á. (2019). Predicción de opinión going concern en clubes de fútbol: Evidencia para la Liga Española. *Contaduría y Administración*, Próximos Artículos.

Allen, D.M. (1974). The relationship between variable selection and data augmentation and a method for prediction. *Technometrics*, 16, 125-127.

Basheer, I.A. y Hajmeer, M. (2000). Artificial Neural Networks: fundamentals, computing, design and application. *Journal of Microbiological Methods*, 43, 3-41.

Bernardos, P.G. y Vosniakos, G.C. (2007). Optimizing feedforward artificial neural network architecture. *Engineering Applications of Artificial Intelligence*, 20 (3), 365-382

Cheng, S. y M. Pecht (2012). Using cross-validation for model parameter selection of sequential probability ratio test. *Expert Systems with Applications*, 39, 8467-8473.

Chong, A.Y.L. (2013). Predicting m-commerce adoption determinants: A neural network approach. *Expert Systems with Applications*, 40 (2), 523-530

Flórez, R. y Fernández, J.M. (2008). *Las Redes Neuronales Artificiales. Fundamentos teóricos y aplicaciones prácticas*. Ed. Netbiblo. Coruña.

Geisser, S. (1975). The predictive sample reuse method with applications. *Journal of American Statistical Association*, 70, 320–328.

Graupe, D. (2013). *Principles of Artificial Neural Networks*. 3rd Edition. Advanced Series in Circuits and Systems. World Scientific

Hair, J. (2008). *Análisis Multivariante*; Editorial Prentice Hall.

Hair, J.F., Anderson R.E., Tatham, R.L. y W.C. Black (1999). *Análisis multivariante*, 5ª edición. Editorial Prentice Hall. Madrid.

Hannan, E.J. y Quinn, B.G. (1979). The determination of the order of an autoregression. *Journal of the Royal Statistical Society, Series B*, 41 (2), 190-195.

Han, J. (2002). *Application of Artificial Neural Networks for Flood Warning Systems*. Doctoral Dissertation: PhD in Civil/Environmental Engineer from North Carolina State University.

Hashem, S. (1992). Sensitivity analysis for feedforward artificial neural networks with differentiable activation functions. *International Joint Conference on Neural Networks*, 419-424.

Hastie, T., Tibshirani, R. y Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer, New York.

Haykin, S. (1999). *Neural Networks. A Comprehensive Foundation*. 2ª edición. Prentice-Hall, New Jersey.

Hilera, J.R. y Martínez, V.J. (1995). *Redes Neuronales Artificiales. Fundamentos, Modelos y Aplicaciones*. Ed. Ra-Ma. Madrid.

Kolmogorov, A.N. (1957). On the representations of continuous functions of many variables by superpositions of continuous functions of one variable and addition. Doklady Akademii Nauk USSR, 114(5), 953- 956.

Kuan, C.M. y White, H. (1994). Artificial Neural Network: An econometric perspective. Econometric Reviews, 13, 1-91

Lisboa, P., Mehridehnavi, A. y Martin, P. (1994). The interpretation of supervised neural networks. Proceedings of the Workshop on Neural Network Applications and Tools, 11-17.

Martín del Brio, B. y Sanz, A. (2001). Redes neuronales y sistemas borrosos. Ed. Ra-Ma. Madrid.

Muller, B. y Reinhardt, J. (1990). Neural Networks: An Introduction. Springer Science & Business Media.

Müller, B., Reinhardt, J. y Strickland, M.K. (2012). Neural Networks: An Introduction. Springer Science & Business Media.

Minsky, M.L. y Papert, S.A. (1969). Perceptrons: An Introduction to Computational Geometry. MIT Press. Cambridge.

Necht-Nielsen, R. (1987). Neurocomputing: Pricking the Human Brain. IEEE Spectrum, 25, 36-41.

Necht-Nielsen, R. (1990). Neurocomputing. Addison Wesley. Nueva York.

Núñez de Castro, L. y Von Zuben, F. J. (1998). Optimised training techniques for feedforward neural networks. Technical Report DCA -RT 03/98. Department of Computer Engineering and Industrial Automation. FEE/UNICAMP, Brasil.

Peña, D. (2002). Análisis de datos multivariantes. Ed. Mc Graw Hill. Madrid.

Russel, S.J. y Norvig, P. (2004). Inteligencia Artificial. Un enfoque moderno, Ed. Pearson Educación. Madrid, 838-851.

Schwarz, G. (1978). Estimating the dimension of a model. Annals of Statistics, 6, 461-464.

Serrano, A. J., Soria, E. y Martín, J. D. (2009). Sistemas de Ayuda a la Decisión Clínica. Open Course Ware. Universidad de Valencia, 31.

Shang, Y., y Wah, B.W., (1996). Global optimization for neural network training. Computer, 29(3), 45-54.

Stone, M. (1974). Cross-validation choice and assessment of statistical predictions. Journal of the Royal Statistical Society: Series B, 36, 111-147.

Takane, Y. (1987). Introduction to special section. Psychometrika, 52 (3), 316-316.

Teixeira, J.P. (2004). A Prosody Model to TTS Systems. Doctoral Dissertation; PhD in Electrotechnical and Computer Engineering from Faculty of Engineer of Porto University.

Yao, J., Li, Y. y Tan, C.H. (2000). Option price forecasting using neural networks. *Omega, The International Journal of Management Science*, 28, 455-466.

Zemouri, R., Racocceanu, D. y Zerhouni, N. (2003). Recurrent radialbasis function network for time-series prediction. *Engineering Applications of Artificial Intelligence*, 16, 453-463.

Zhang, Y. y Yang, Y. (2015). Cross-validation for selecting a model selection procedure. *Journal of Econometrics*, 187, 95–112.

CAPÍTULO 3: DATOS Y VARIABLES

En el presente capítulo comienza el desarrollo de los aspectos empíricos de la investigación. Con este objetivo, en primer lugar, se exponen las características de la base de datos utilizada y de la muestra seleccionada. A tal efecto, la muestra se ha dividido en diferentes submuestras con objeto de analizar la predicción de quiebra 1, 2 y 3 años antes de su declaración. Todo ello, a su vez, para tres regiones (Europa, Asia y Norte América) y también con un carácter global (con información conjunta de las tres regiones). En segundo lugar, se presentan las variables utilizadas, su descripción y su forma de cálculo. En el capítulo siguiente, se expondrán los resultados obtenidos.

3.1. DATOS

La muestra utilizada en el presente trabajo está integrada por 220 empresas no financieras en situación legal de quiebra, e igual cantidad de empresas no quebradas, todas ellas pertenecientes a tres regiones del mundo (Asia, Europa y Norte América). Los datos obtenidos de las empresas de la muestra corresponden al período comprendido entre el año 1990 y el año 2013 (Tabla 3.1).

TABLA 3.1. PAÍSES REPRESENTADOS EN LA MUESTRA

Asia	Europa	Norte América
Corea del Sur	Alemania	Bermudas
Japón	Austria	Canadá
Singapur	Dinamarca	Estados Unidos
Taiwán	España	
	Francia	
	Holanda	
	Irlanda	
	Italia	
	Luxemburgo	
	Noruega	
	Portugal	
	Reino Unido	
	Suecia	
	Suiza	

La mayoría de los estudios previos relacionados con la predicción de quiebra han utilizado información correspondiente a un año antes de la quiebra (Zmijewski, 1984; McKee y Lensberg, 2002), y sólo algunos, información con dos y tres años de antelación (Korol, 2013; Betz et al., 2014). El presente trabajo utiliza información de hasta dos años antes de la situación de quiebra, definiendo dos grupos de datos (t-1 en referencia a datos con un año de antelación a la quiebra y t-2 para datos con dos años de antelación). La tabla 3.2 especifica el número de empresas por región que integra cada uno de los grupos de la muestra.

TABLA 3.2. DISTRIBUCIÓN DE LOS DATOS. NÚMERO DE EMPRESAS QUEBRADAS Y SOLVENTES

		Total			Datos de entrenamiento		Datos de testeo	
Región		Total Nº obs. por horizonte	Total Quebradas	Total No quebradas	Quebradas	No quebradas	Quebradas	No quebradas
ASIA	t-1	96	48	48	34	34	14	14
	t-2	96	48	48	34	34	14	14
	Horizonte total	192	96	96	68	68	28	28
EUROPA	t-1	172	86	86	60	60	26	26
	t-2	172	86	86	60	60	26	26
	Horizonte total	344	172	172	120	120	52	52
AMÉRICA	t-1	172	86	86	60	60	26	26
	t-2	168	84	84	59	59	25	25
	Horizonte total	340	170	170	119	119	51	51
GLOBAL	t-1	440	220	220	154	154	66	66
	t-2	436	218	218	152	152	66	66
	Horizonte total	876	648	648	306	306	132	132

3.1.1. OBTENCIÓN DE LOS DATOS

Los datos utilizados en la presente investigación provienen de la base COMPUSTAT, que suministra información contable y financiera de las empresas cotizadas en los respectivos índices bursátiles de sus países. COMPUSTAT es publicada por Standard and Poor's (S&P's) y abarca 99.000 valores globales, que cubren el 99% de la capitalización bursátil total del mundo. El tipo de información publicada por Compustat está clasificada por países (índices bursátiles nacionales), y dividida por sectores económicos a partir del índice llamado Estándares de Clasificación Industrial Global -*Global Industry Classification System Codes*- (GICS).

GICS es una colaboración entre Standard & Poor's y Morgan Stanley Capital International. Los códigos GICS contienen 8 dígitos correspondientes a diversas actividades comerciales o industriales divididas en una jerarquía de sectores, grupos, industrias y subsectores (Tabla 3.3). En total, hay 10 sectores económicos, 23 grupos industriales, 59 industrias y 123 categorías sub-industriales. Todos los sectores tienen un código de identificación de 2 dígitos (los 2 dígitos más a la izquierda); todos los grupos industriales tienen un código de identificación de 4 dígitos (los 4 dígitos más a la izquierda); todas las industrias tienen un código de identificación de 6 dígitos (más a la izquierda, 6 dígitos), y todas las industrias secundarias usan el código de identificación completo de 8 dígitos.

Tabla 3.3. SECTORES E INDUSTRIAS DE GICS (COMPUSTAT)

GICS Sector	Grupo Industrial
10 Energía	1010 Energía
15 Materiales	1510 Materiales
20 Industrial	2010 Bienes de Capital 2020 Servicios Comerciales y Profesionales 2030 Transporte
25 Consumo Discrecional	2510 Automóviles y Componentes 2520 Bienes de Consumo y Ropa 2530 Servicios de Consumo 2540 Medios de Comunicación 2550 Venta al por Menor
30 Consumer Básico	3010 Venta al por Menor de Alimentos y Básicos 3020 Comida, Bebidas y Tabaco 3030 Productos Domésticos y Personales
35 Salud	3510 Equipos y Servicios de Cuidado de la Salud 3520 Farmacéuticas, Biotecnología y Ciencias Naturales
40 Financiero	4010 Bancos 4020 Finanzas Diversificadas 4030 Seguros 4040 Inmobiliaria
45 Tecnología de la Información	4510 Software y Servicios 4520 Tecnología Hardware y Equipo 4530 Semiconductores y Equipos Semiconductores
50 Telecomunicaciones	5010 Servicios de Telecomunicación
55 Servicios Públicos	5510 Servicios Públicos
60 Industria Inmobiliaria	6010 Inmobiliaria

De la base de datos COMPUSTAT se ha seleccionado una muestra aleatoria de empresas integrada tanto por empresas quebradas como por empresas no quebradas. Para ello, el concepto de quiebra utilizado ha sido el de empresas que salen del registro de sus respectivos índices bursátiles a fin de año -31 de diciembre- (utilizando definiciones COMPUSTAT). Tales empresas no tienen cotización de cierre de mercado debido a que han sido clasificadas (declaradas legalmente)

como empresas quebradas. Conforme a la legislación de Estados Unidos (11 U.S. Code Chapter 11), país de origen de la base de datos COMPUSTAT, la situación de quiebra prevé una reorganización, generalmente involucrando a una corporación o sociedad. Un deudor acogido al capítulo 11 suele proponer un plan de reorganización para mantener viva su empresa y pagar a los acreedores a lo largo de un tiempo establecido.

La Tabla 3.4 ofrece un destalle de la distribución sectorial de las empresas de la muestra.

Tabla 3.4. DISTRIBUCIÓN SECTORIAL DE LA MUESTRA

	GICS*									
	10	15	20	25	30	35	45	50	55	Total
Asia (t-1)	-	6	32	36	6	-	16	-	-	96
Asia (t-2)	-	6	32	36	6	-	16	-	-	96
Europa (t-1)	4	6	40	46	12	-	52	8	4	172
Europa (t-2)	4	6	42	44	12	-	52	8	8	172
América (t-1)	14	14	22	64	8	20	22	2	6	172
América (t-2)	14	14	22	62	8	20	20	2	6	168
Global (t-1)	18	26	94	146	26	20	90	10	10	440
Global (t-2)	18	26	96	142	26	20	88	10	10	436

*Códigos GICS: 10-Energía-, 15-Materiales-, 20-Industriales-, 25-Productos de Consumo no Básico-, 30-Productos de Primera Necesidad-, 35-Servicios de Salud-, 45-Tecnología de Información-, 50-Servicios de Telecomunicaciones-, 55-Servicios de Utilidad Pública-

Con objeto de validar los modelos estimados y probar su capacidad predictiva se han utilizado muestras de testeo, diferentes y sin relación con las utilizadas para la estimación de los modelos. En consecuencia, se procedió a dividir los grupos datos de la muestra en dos subgrupos

diferentes, uno que se utiliza para construir los modelos (datos de entrenamiento) y otro para probarlos (datos de testeo).

3.2. VARIABLES

3.2.1. PROCEDIMIENTO DE SELECCIÓN DE LAS VARIABLES

En el presente trabajo se ha considerado un total de 11 variables independientes como posibles predictores de quiebra. Estas variables han sido seleccionadas entre aquéllas con mayor frecuencia de utilización en los estudios previos, acorde al trabajo de revisión de la literatura realizado por Bellovary et al. (2007), donde revisa los resultados y conclusiones de más de 100 trabajos. La mayoría de ellas son de tipo cuantitativo, correspondiéndose con distintos ratios económico-financieros obtenidos a partir de la información contable de las empresas pertenecientes a la muestra. Tales variables recogen aspectos relacionados con la rentabilidad, el endeudamiento, la liquidez, la eficiencia y el sector industrial (Tablas 3.5 y 3.6). Finalmente, y como variable dependiente, se ha empleado una variable dummy de tipo binomial que identifica a las empresas como quebradas o como no quebradas.

Tabla 3.5. DEFINICIÓN DE LAS VARIABLES INDEPENDIENTES

Código	Definición	Signo Esperado	Número de estudios¹
V1	Ingresos Netos/Activos Totales	-	54
V2	Activos Circulantes/Pasivos Circulantes	-	51
V3	Capital de Explotación/Activos Totales	-	45
V4	Beneficio No Distribuido/Activos Totales	-	42
V5	Beneficio antes de Intereses e Impuestos/Activos Totales	-	35
V6	Ventas/Activos Totales	-	32
V7	Activos Circulantes más Tesorería/Pasivos Circulantes	-	30
V8	Deuda Total/Activos Totales	+	27
V9	Activos Circulantes/Activos Totales	-	26
V10	Ingresos Netos/Patrimonio Neto	-	23
V11	Código del Sector Industrial	+/-	
Región	Región perteneciente la empresa (1 para Asia, 2 para Europe y 3 para America).		

¹ Número de estudios que utilizaron cada variable según la revisión de Bellocary et al. (2007).

TABLA 3.6. DEFINICIÓN DE LAS PARTIDAS INCLUIDAS EN LAS VARIABLES UTILIZADAS

Activo Corriente	Activos vinculados al ciclo normal de explotación que la empresa espera vender, consumir o realizar en el transcurso del mismo (con carácter general el ciclo normal de explotación no excederá de un año) + aquellos activos no vinculados al proceso de explotación, pero cuyo vencimiento, enajenación o realización se espera se realice en el corto plazo + efectivo y otros activos líquidos
Activo No Corriente	Todos aquellos activos que no se consideran activos corrientes
Beneficio Después de Impuestos	Resultado neto de la empresa, una vez considerados todos los ingresos y todos los gastos.
Beneficio No Distribuido	Ingresos, tras el pago de impuestos, que no son repartidos en forma de dividendos
Capital de Explotación	Son los recursos de largo plazo que una empresa tiene para financiar las necesidades operativas de corto plazo, una vez que ha financiado sus activos fijos. Su cálculo sería (Deuda a largo plazo + Patrimonio Neto) - Activo Fijo
Deudas a Largo Plazo	Financiación ajena con vencimiento superior a un año
Deuda Total	Financiación ajena con vencimiento superior a un año + Financiación ajena con vencimiento inferior a un año
EBIT	Beneficios antes de Intereses e Impuestos
EBITDA	Beneficios antes de Intereses, Impuestos, Amortizaciones y Depreciaciones

TABLA 3.6. DEFINICIÓN DE LAS PARTIDAS INCLUIDAS EN LAS VARIABLES UTILIZADAS (CONTINUACIÓN)

Gastos Financieros	Coste de la financiación ajena
Ingresos	Ingresos de explotación
Ingresos Netos	Ingresos de explotación-Impuestos
Margen de Beneficio Bruto	EBITDA/Ingresos de explotación
Pasivo Corriente	Pasivos vinculados al ciclo normal de explotación que la empresa espera liquidar en el transcurso del mismo (con carácter general el ciclo normal de explotación no excederá de un año) + aquellos pasivos financieros clasificados como mantenidos para negociar, excepto los derivados financieros con vencimiento superior a un año
Pasivo No Corriente	Toda aquella financiación ajena no considerada como pasivo corriente
Patrimonio Neto	Recursos propios de la empresa
Tesorería	Activos líquidos
Total Activo	Activo no corriente + Activo corriente.
Total Pasivo	Total financiación ajena de la empresa. Suma de Pasivo corriente y Pasivo no corriente.
Ventas	Ingresos obtenidos a través de la venta del inventario (bienes y servicios)

BIBLIOGRAFÍA CAPÍTULO 3

Bellovary J.L., Giacomino D.E. y Akers M.D. (2007) A review of bankruptcy prediction studies: 1930 to present. *Journal of Financial Education*, 33 (4), 3-41.

Betz, F., Oprica, S., Peltonen, T.A. y Sarlin, P. (2014). Predicting distress in European banks. *Journal of Banking & Finance*, 45, 225-241.

Global Industry Classification Standard (GICS). Standard & Poor's y Morgan Stanley Capital International (<https://www.unm.edu/~maj/Security%20Analysis/GICS.pdf>)

Korol, T. (2013). Early warning models against bankruptcy risk for Central European and Latin American enterprises. *Economic Modelling*, 31, 22-30.

Ley 22/2003 de 9 de Julio, Concursal.

McKee, T.E. y Lensberg, T. (2002). Genetic programming and rough sets: A hybrid approach to bankruptcy classification. *European Journal of Operational Research*, 138, 436-451.

U.S. Code: Title 11 - BANKRUPTCY | US Law.

Zmijewski, M.E. (1984). Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting Research*, 22, 59-81.

CAPÍTULO 4: RESULTADOS

Este capítulo completa el desarrollo de los aspectos empíricos del presente trabajo de investigación, ofreciendo un detalle de los resultados obtenidos.

Dichos resultados se presentan para los modelos globales y regionales, y para cada uno de los dos períodos considerados ($t-1$ y $t-2$).

Para facilitar la construcción de los modelos (análisis confirmatorio) se ha efectuado previamente un análisis exploratorio de las variables consideradas con objeto de evaluar si pudieran ser relevantes en la estimación predictiva de la quiebra.

4.1. RESULTADOS PARA $t-1$

4.1.1. MODELO GLOBAL

4.1.1.1. Análisis Exploratorio

En el análisis exploratorio se llevará a cabo un estudio descriptivo para conocer los principales parámetros estadísticos de las variables utilizadas (media, mediana, desviación típica, mínimo y máximo). Posteriormente, se estudiará la normalidad de dichas variables, lo que permitirá comprobar si procede la aplicación de tests paramétricos o no paramétricos. Y en última instancia, se efectuará un análisis de correlación entre las diferentes variables.

A partir del análisis exploratorio, se intentará deducir qué variables podrían resultar relevantes en la predicción mediante el modelo global. Este análisis será verificado posteriormente con un análisis confirmatorio específico.

El análisis descriptivo se realiza, de forma diferenciada, para las empresas quebradas y no quebradas de la muestra global. En esta muestra se encuentran incluidas compañías representativas de todas las regiones examinadas, un año antes de la entrada en quiebra. El objetivo de este análisis es, pues, realizar una comparativa entre los parámetros estadísticos obtenidos de cada variable, diferenciando según sean las empresas quebradas o no quebradas.

En la tabla 4.1 se exponen los resultados del análisis descriptivo realizado para la muestra global un año previo a la quiebra. Observando las medias obtenidas para cada una de las variables, se aprecia que en $t-1$, variables como V2, V6 y V7 presentan valores superiores en las empresas no quebradas con respecto a las quebradas. Estos resultados son acordes a lo establecido en la literatura previa. Además, las medianas de cada una de las variables, de forma sistemática, presentan valores superiores en las empresas no quebradas. El 50% de los valores medios de las empresas no quebradas superan al de las empresas quebradas. Para el caso de la mediana este porcentaje es también del 50%.

Con respecto a las desviaciones típicas, así como de los mínimos y máximos, se puede comprobar la enorme dispersión existente en buena parte de los casos. Esta dispersión era presumible dadas las características propias de la información financiera, lo que ya ha sido constatado previamente por algunos autores (Fernández et al., 2009).

TABLA 4.1. ESTADÍSTICOS DESCRIPTIVOS (MODELO GLOBAL, t-1)

	Media		Mediana		Desviación Típica		Mínimo		Máximo	
	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas
V1	0,037	0,073	0,026	0,058	-0,261	0,414	-0,751	-9,245	5,263	2,028
V2	1,895	1,002	1,542	0,851	1,219	1,231	-2,052	-2,743	24,272	57,992
V3	0,202	0,204	0,152	0,161	0,12	0,276	0,024	-0,063	0,974	0,997
V4	0,083	0,569	0,043	0,386	-0,662	54,189	-2,774	-7,717	5,286	2,715
V5	0,072	0,088	0,042	0,047	-15,536	0,234	-9,128	-2,858	2,416	3,196
V6	1,092	0,604	0,645	0,357	1,093	0,711	-4,657	-1,865	4,982	5,614
V7	1,246	0,767	0,751	0,486	0,777	1,078	-3,165	-2,156	6,446	2,146
V8	0,229	0,178	0,151	0,076	0,477	0,384	0,008	-0,486	1,545	0,816
V9	0,496	0,211	0,312	0,167	0,506	0,232	-0,589	-0,287	1,284	0,846
V10	0,101	0,294	0,067	0,195	-3,726	5,352	-2,846	-5,641	0,762	1,268

Aunque a partir de este análisis descriptivo se puede apreciar indicios de qué variables podrían resultar relevantes en el estudio de la quiebra, aún no es posible llegar a concluir si estas variables son realmente significativas. Por tanto, este primer análisis resultaría insuficiente para valorar si las diferencias presentadas se deben a su significación o a la variabilidad propia que presentan las variables financieras. Este hecho pone de manifiesto la necesidad de realizar diferentes tests que ayuden a valorar la significación de tales variables en la estimación de la quiebra.

A continuación, es necesario analizar la normalidad de las distintas variables. Este análisis es apropiado para poder determinar qué tipos de tests son aplicables para el análisis de la significación de cada una de las variables, de forma individual, en la predicción de la quiebra. En el caso de resultar ser variables distribuidas normalmente, los tests a aplicar serán los paramétricos. Por el contrario, en caso de no distribuirse de forma normal, los tests que se aplicarán serán los no paramétricos.

Para aclarar esta situación, el test que se propone aplicar es el de Kolmogorov-Smirnov, cuya hipótesis nula es que los datos presentan una distribución normal. El cumplimiento del supuesto de normalidad implica que cada variable, en cada una de las muestras, y tanto para las empresas no quebradas como para las quebradas, se distribuye normalmente, con un nivel de significación igual o superior al 5%.

La tabla 4.2 muestran los resultados del test de Kolmogorov-Smirnov. Como se puede comprobar, todas las variables en t-1 presentan un nivel de significación inferior al 5%. En consecuencia, se rechaza la hipótesis nula de normalidad.

El quebrantamiento de la normalidad tiene como consecuencia que, para continuar con el análisis descriptivo, deberán aplicarse tests no paramétricos, como se ha apuntado anteriormente.

TABLA 4.2 ANÁLISIS DE NORMALIDAD (MODELO GLOBAL, t-1)

	No quebradas		Quebradas	
	K-S	Sig,	K-S	Sig,
V1	0,325	0,000	0,262	0,000
V2	0,124	0,000	0,149	0,000
V3	0,485	0,000	0,527	0,000
V4	0,450	0,000	0,480	0,000
V5	0,479	0,000	0,521	0,000
V6	0,092	0,000	0,103	0,000
V7	0,211	0,000	0,173	0,000
V8	0,093	0,000	0,141	0,000
V9	0,068	0,000	0,052	0,000
V10	0,427	0,000	0,516	0,000
V11	0,292	0,000	0,305	0,000

NOTA: K-S: test de Kolmogorov-Smirnov

A continuación, se aplicará a cada una de las variables diferentes tests no paramétricos con el objetivo de constatar si éstas son significativamente distintas entre las empresas quebradas y no quebradas. Hay que puntualizar que los tests no paramétricos son menos robustos que los tests paramétricos, pero presentan, como principal ventaja, el no exigir la normalidad en los datos.

Se propone la aplicación de dos tests. Por un lado, la aplicación del test de Mann-Whitney y, por otro, el test de Kolmogorov-Smirnov.

El contraste U de Mann-Whitney parte de la hipótesis de que dos poblaciones son independientes entre sí, y la hipótesis nula a contrastar es que las dos poblaciones se distribuyen de la misma manera. En caso de no aceptarse la hipótesis nula implicaría una

diferencia en la forma o en la dispersión de una población con respecto a la otra (López y López, 1996). Este test sería análogo al test “t” que se utiliza en los tests paramétricos.

Según Visauta (2003), el test de Kolmogorov-Smirnov para dos muestras sirve para contrastar si dos muestras proceden de poblaciones con la misma distribución, basándose en la comparación de sus funciones de distribución. La hipótesis nula, en este caso, es que no existen diferencias significativas entre las distribuciones de ambas muestras.

TABLA 4.3 TESTS NO PARAMÉTRICOS (MODELO GLOBAL, t-1)

	Test de Mann-Whitney		Test de Kolmogorov-Smirnov	
	M-W	Sig.	K-S	Sig.
V1	25,540	0,000	12,138	0,000
V2	-10,047	0,000	5,387	0,000
V3	5,120	0,000	3,162	0,000
V4	-17,129	0,000	9,507	0,000
V5	-5,572	0,076	2,291	0,004
V6	-11,645	0,000	5,346	0,000
V7	10,450	0,000	5,037	0,000
V8	-2,102	0,211	1,389	0,075
V9	2,321	0,016	5,215	0,000
V10	1,927	0,004	1,485	0,000

NOTA: K-S: test de Kolmogorov-Smirnov; M-W: test de Mann-Whitney

Como puede comprobarse en la tabla 4.3, el test de Mann-Whitney rechaza la hipótesis nula en ocho de las diez variables analizadas, aceptándose tan solo la igualdad de distribuciones en las variables V5 y V8. En estas variables se rechaza la hipótesis nula con un nivel de significación del 5%. Sin embargo, sólo se acepta la hipótesis nula de igualdad en la distribución entre empresas quebradas y no quebradas de la variable V8 mediante el test de Kolmogorov-

Smirnov, rechazándose en el resto de las variables consideradas en la muestra global.

Por tanto, y dado el alto porcentaje de significación en buena parte de las variables consideradas, parece posible la consecución de fiables modelos de predicción, por tratarse de variables que, en principio, resultan ser adecuadas para estimar la quiebra.

Para concluir el análisis exploratorio, se procederá a la estimación de las correlaciones que se originan entre las variables explicativas, incluida la variable dependiente. En la tabla 4.4 se muestra el análisis de correlación bilateral para el modelo global correspondiente a t-1. Para examinar las correlaciones se ha aplicado el coeficiente de correlación de Pearson. Los valores de los diferentes coeficientes estarán comprendidos entre -1 (una relación negativa perfecta) y $+1$ (una relación positiva perfecta). Un valor 0 indica que no existe una relación lineal entre las variables seleccionadas.

Este análisis facilita conocer a priori tanto el signo de la relación entre variables como el grado de relación existente entre las mismas. Se deberá, por tanto, tener especial atención en el análisis confirmatorio con aquellas variables que muestren una elevada correlación, con el fin de no contar con variables redundantes en los modelos. Prestando atención a los resultados de la tabla 4.4 puede comprobarse que el mayor valor de correlación que existe se origina entre las variables V3 y V5, con un coeficiente de correlación de Pearson de 0,758. La elevada correlación de esta pareja de variable era previsible ante la similitud en el cálculo de las mismas. Haciendo balance del análisis exploratorio realizado, es posible concluir que, todas las variables consideradas, excluyendo las variables V6 y V11, exhiben signos de ser variables relevantes en el análisis de la quiebra.

TABLA 4.4. ANÁLISIS DE CORRELACIÓN BILATERAL (MODELO GLOBAL, t-1)

	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11	Quiebra
V1	1	0,306**	0,494**	0,022	0,423**	0,025	0,263**	-0,597**	0,089	0,125**	-0,050	-0,454**
V2	0,306**	1	0,119*	-0,358**	0,081	-0,135**	0,856**	-0,342**	0,260**	-0,002	0,072	-0,289**
V3	0,494**	0,119*	1	0,059	0,758**	0,041	0,092*	-0,501**	0,027	-0,014	-0,030	-0,097*
V4	0,022	-0,358**	0,059	1	0,054	0,081	-0,464**	0,035	-0,110*	0,000	-0,075	-0,056
V5	0,423**	0,081	0,758**	0,054	1	0,051	0,063	-0,281**	0,005	-0,009	0,023	-0,066
V6	0,025	-0,135**	0,041	0,081	0,051	1	-0,215**	-0,048	0,334**	-0,034	-0,119**	0,001
V7	0,263**	0,856**	0,092*	-0,464**	0,063	-0,215**	1	-0,341**	0,232**	-0,009	0,115*	-0,244**
V8	-0,597**	-0,342**	-0,501**	0,035	-0,281**	-0,048	-0,341**	1	-0,209**	-0,072	-0,090	0,385**
V9	0,089	0,260**	-0,027	-0,110*	0,005	0,334**	0,232**	-0,209**	1	0,021	0,013	0,021
V10	0,125**	-0,002	-0,014	0,000	-0,009	-0,034	-0,009	-0,072	0,021	1	0,050	-0,141**
V11	-0,050	0,072	-0,030	-0,075	0,023	-0,119**	0,115*	-0,090	0,013	0,050	1	-0,001
Quiebra	-0,454**	-0,289**	-0,097*	-0,056	-0,067	0,001	-0,244**	0,385**	0,022	-0,141**	0,000	1

**Correlación significativa a nivel 0,01 (bilateral)

*Correlación significativa a nivel 0,05 (bilateral)

4.1.1.2. Análisis Confirmatorio

Una vez finalizado el análisis exploratorio, en este apartado se realizará un análisis confirmatorio de los resultados. En este sentido, se estimará un modelo global, sin incluir la variable regional que representa la distinción entre regiones utilizando PMC. Hay que precisar que PMC cuenta con la ventaja de propiciar una alta precisión de resultados (aportando también un beneficio explicativo e interpretativo, más allá del puramente predictivo).

Cada uno de los modelos contruidos con PMC será validado en un set de datos fuera de la muestra. Este procedimiento permitirá testar la capacidad de generalización de los modelos, característica esencial en cualquier estudio de esta naturaleza, en la medida en que su principal utilidad es poder utilizarlos con observaciones no conocidas en la etapa de estimación de éstos o, lo que es lo mismo, para comprobar su capacidad de predicción. A tal efecto, un 70% de los datos muestrales se utilizarán para la estimación de los modelos, y el 30% restante para la denominada muestra de testeo.

En la tabla 4.5 y en la figura 4.1 se muestran los resultados del modelo global con información correspondiente a t-1 (sin la variable regional). El modelo está constituido por una capa de entrada, en la cual hay tantos nodos o neuronas como variables se han utilizado (11 variables), una capa oculta con 7 neuronas, y una capa de salida con 2 neuronas, pues se trata de un modelo dicotómico con dos posibilidades de respuesta: quebradas y no quebradas. Dentro de las funciones de activación existentes, se ha obtenido el resultado óptimo con la función de tangente hiperbólica para el caso de la capa oculta, y de la función Softmax, en el caso de la capa de salida. De esta forma, el nivel de clasificación obtenido dentro de la muestra asciende al 85,04%,

clasificándose correctamente el 92,58% las empresas no quebradas y el 77,67% de las quebradas.

Si generalizamos el modelo en la muestra de testeo, el nivel de clasificación ha ascendido al 88,79%, prediciendo con mayor precisión para las empresas no quebradas (90,76%) que para las quebradas (86,73%).

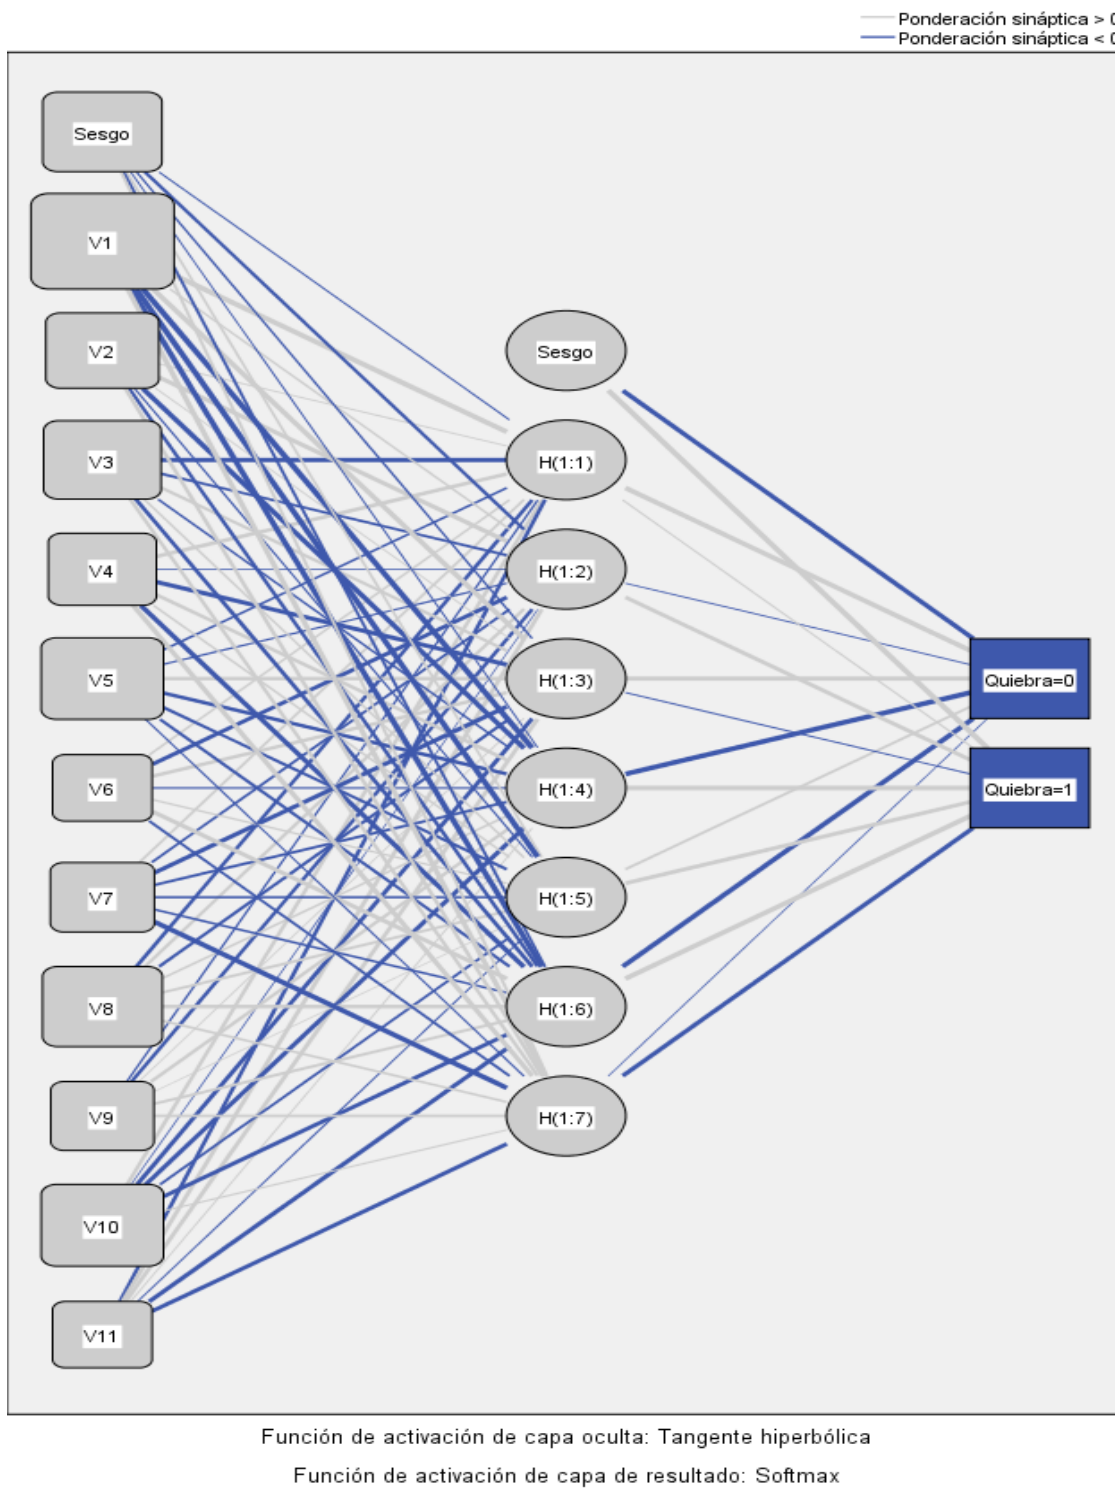
Por su parte, el análisis de sensibilidad realizado nos ha permitido determinar que las variables de mayor impacto han sido V3, V5 y V8 (con una importancia normalizada del 100,00%, 75,60% y 71,10%, respectivamente).

Finalmente, y con objeto de valorar la bondad del ajuste del modelo se empleó la curva COR (Característica Operativa del Receptor). Ésta presenta la sensibilidad de una prueba diagnóstica que produce resultados continuos, en función de los falsos positivos, para distintos puntos de corte (Bradley, 1997). Un parámetro para evaluar dicha bondad es el área bajo la curva (AUC). Esta área puede interpretarse como la probabilidad de que, ante un par de empresas, una quebrada y la otra no quebrada, la prueba las clasifique correctamente. Para nuestro caso, la curva COR ha obtenido un valor del 0,902, lo que supondría una alta fiabilidad del poder de clasificación del modelo.

TABLA 4.5 MODELO GLOBAL, t-1

Ajuste del modelo	Valor
Número de neuronas en capa de entrada	11
Número de capas ocultas	1
Número de neuronas en capa oculta	7
Función de activación capa oculta	Tangente hiperbólica
Función de activación capa de salida	Softmax
Curva COR	0,902
Matriz de clasificación	%
Dentro de la muestra	85,04
Quebradas	77,67
No quebradas	92,58
Muestra de testeo	88,79
Quebradas	86,73
No quebradas	90,76
Variables	Importancia Normalizada
V1	46,20%
V2	36,40%
V3	100,00%
V4	26,40%
V5	75,60%
V6	8,90%
V7	17,80%
V8	71,10%
V9	65,90%
V10	56,70%
V11	8,30%

FIGURA 4.1. ARQUITECTURA DE LA RED. MODELO GLOBAL, t-1



4.1.2. RESULTADOS MODELO ASIA

4.1.2.1. Análisis Exploratorio

Al igual que para el modelo global construido con la muestra de empresas pertenecientes a todas las regiones consideradas, en este apartado se aborda el análisis exploratorio para el modelo construido con empresas pertenecientes a la región de Asia.

En la tabla 4.7 se detallan los resultados del análisis descriptivo realizado con la muestra de Asia para t-1. Observando las medias obtenidas para cada una de las variables, se comprueba que V1, V3, V4, V5 y V10 presentan medias con diferente signo según se trate de empresas quebradas o no quebradas. En general, el 90% de los valores medios en las empresas no quebradas supera al de las compañías quebradas. Para el caso de la mediana, este porcentaje alcanza el 80%. Por su parte, la desviación típica presenta valores moderados, lo que indica un grado de dispersión satisfactorio.

TABLA 4.7. ESTADÍSTICOS DESCRIPTIVOS (MODELO ASIA, t-1)

	Media		Mediana		Desviación Típica		Mínimo		Máximo	
	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas
V1	0,032	-0,210	0,019	0,008	0,027	0,391	-0,685	-7,891	5,232	1,598
V2	1,640	0,983	1,483	0,741	0,689	0,587	-2,586	-2,265	5,896	5,180
V3	0,194	-0,138	0,146	-0,082	0,150	0,401	0,015	-0,083	1,162	0,914
V4	0,229	-0,268	0,083	-0,145	0,196	0,484	-2,157	-2,716	5,155	2,165
V5	0,055	-0,043	0,047	0,022	0,039	0,120	-1,124	-2,754	2,165	3,876
V6	1,123	1,039	0,729	0,357	0,555	0,514	-3,152	-1,745	4,428	5,891
V7	1,145	0,665	0,863	0,518	0,563	0,534	-2,745	-2,075	5,982	2,879
V8	0,243	0,549	0,157	0,415	0,165	0,341	0,017	-0,586	1,981	0,865
V9	0,572	0,562	0,354	0,383	0,177	0,212	-0,448	-0,177	1,784	1,298
V10	0,073	-0,498	0,028	-0,261	0,075	3,106	-0,326	-2,789	0,816	1,985

En la tabla 4.8 se muestran los resultados del test de Kolmogorov-Smirnov para las empresas no quebradas y quebradas pertenecientes a la región asiática, con un nivel de significación del 5%. Con las excepciones de V2, para el caso de las empresas quebradas, y V3, para las empresas no quebradas, todas las variables presentan significatividad al nivel del 5%. En consecuencia, se rechazaría la hipótesis nula de normalidad. El incumplimiento de la normalidad implica necesariamente la aplicación de tests no paramétricos.

TABLA 4.8. ANÁLISIS DE NORMALIDAD (MODELO ASIA, t-1)

	NO QUEBRADAS		QUEBRADAS	
	K-S	Sig.	K-S	Sig.
V1	0,124	0,000	0,305	0,000
V2	0,282	0,005	0,255	0,073
V3	0,136	0,096	0,082	0,002
V4	0,181	0,000	0,248	0,000
V5	0,159	0,000	0,181	0,000
V6	0,224	0,000	0,257	0,000
V7	0,147	0,023	0,221	0,001
V8	0,121	0,000	0,152	0,019
V9	0,175	0,058	0,174	0,000
V10	0,238	0,007	0,323	0,018
V11	0,513	0,000	0,563	0,000

NOTA: K-S: test de Kolmogorov-Smirnov

Según los resultados que aparecen en la tabla 4.9, se acepta la hipótesis nula de igualdad de distribuciones para V3, V5 y V9, dado que se presentan en los tests de Mann-Whitney y Kolmogorov-Smirnov con niveles de significación superiores al 5%. Por su parte, V9 sólo muestra niveles de significatividad superiores al 5% en el test de Mann-Whitney. Con las excepciones apuntadas, se rechaza la hipótesis nula de igualdad en las distribuciones de las variables consideradas para la región de Asia.

TABLA 4.9. TESTS NO PARAMÉTRICOS (MODELO ASIA, t-1)

	Test de Mann-Whitney		Test de Kolmogorov-Smirnov	
	M-W	Sig.	K-S	Sig.
V1	3,525	0,000	3,235	0,000
V2	-4,784	0,000	2,464	0,000
V3	1,731	0,048	1,762	0,171
V4	5,374	0,000	3,552	0,000
V5	-0,226	0,840	0,753	0,792
V6	-3,451	0,000	2,158	0,001
V7	3,267	0,001	1,563	0,016
V8	0,265	0,969	0,742	0,886
V9	0,764	0,766	2,982	0,000
V10	5,855	0,000	2,589	0,000
V11	-2,346	0,000	3,852	0,000

NOTA: K-S: test de Kolmogorov-Smirnov; M-W: test de Mann-Whitney

A partir de los resultados conseguidos, y teniendo en cuenta la significación de casi todas las variables, parece posible la construcción de apropiados modelos de predicción, por tratarse de variables que a priori resultan ser adecuadas para estimar la quiebra.

Respecto a los resultados del análisis de correlación bilateral para el modelo correspondiente a Asia en t-1 (tabla 4.10), se detecta una elevada correlación entre las variables V2 y V7 (con un coeficiente de 0,882). Asimismo, la correlación es elevada entre las parejas V1 y V4 (0,736) y V2 y V3 (0,721).

TABLA 4.10 ANÁLISIS DE CORRELACIÓN BILATERAL (MODELO ASIA, t-1)

Variables	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11	Quiebra
V1	1	0,239	0,519	0,736	0,517	-0,064	0,195	-0,460	0,088	0,374	0,150	-0,431**
V2	0,239	1	0,721	0,378	0,202	-0,177	0,882	-0,334	0,406	0,060	0,158	-0,506**
V3	0,519	0,721	1	0,638	0,288	-0,056	0,630	-0,654	0,545	0,029	0,211	-0,535**
V4	0,736	0,378	0,638	1	0,519	-0,039	0,334	-0,518	0,212	0,338	0,098	-0,572**
V5	0,517	0,202	0,288	0,519	1	0,019	0,181	0,046	-0,035	0,201	0,069	-0,490**
V6	-0,064	-0,177	-0,056	-0,039	0,019	1	-0,202	-0,131	0,226	0,086	-0,080	-0,057
V7	0,195	0,882	0,630	0,334	0,181	-0,202	1	-0,317	0,363	0,051	0,148	-0,456**
V8	-0,460	-0,334	-0,654	-0,518	0,046	-0,131	-0,317	1	-0,266	0,062	-0,046	0,525**
V9	0,088	0,406	0,545	0,212	-0,035	0,226	0,363	-0,266	1	0,125	-0,038	-0,071
V10	0,374	0,060	0,029	0,338	0,201	0,086	0,051	0,062	0,125	1	0,094	-0,103
V11	0,150	0,158	0,211	0,098	0,069	-0,080	0,148	-0,046	-0,038	0,094	1	0,000
Quiebra	-0,431**	-0,506**	-0,535**	-0,572**	-0,490**	-0,057	-0,456**	0,525**	-0,071	-0,103	0,000	1

**Correlación significativa a nivel 0,01 (bilateral)

*Correlación significativa a nivel 0,05 (bilateral)

Haciendo balance del análisis exploratorio realizado, es posible concluir que, prácticamente todas las variables, excepto la variable V11, muestran signos de ser variables relevantes en el análisis de la quiebra.

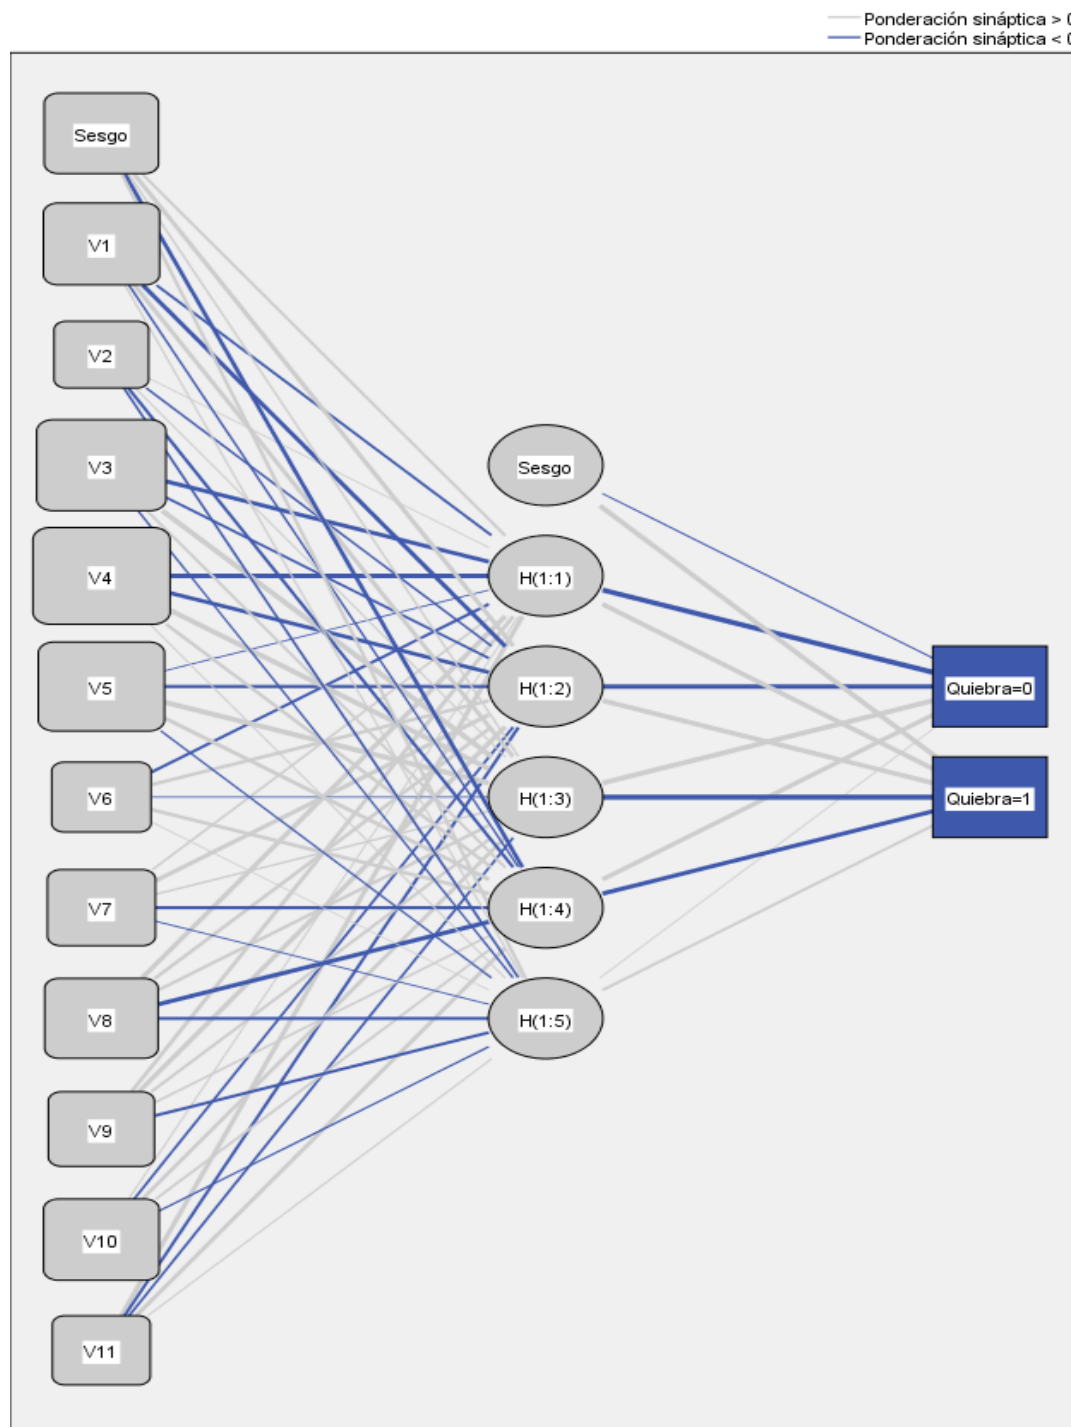
4.1.2.2. Análisis Confirmatorio

En la tabla 4.11 y en la figura 4.2 se muestran los resultados del modelo PMC construido con la muestra de Asia en t-1. El modelo consta de una capa de entrada con 11 neuronas, una capa oculta con 5 neuronas, y una capa de salida con 2 neuronas. Con esta estructura, el nivel de clasificación obtenido dentro de la muestra asciende al 86,42%, clasificándose correctamente el 88,49% de las empresas no quebradas y el 82,63% de las quebradas. En la muestra de testeo el nivel de clasificación ha ascendido al 89,29%, prediciendo con mayor precisión para las empresas quebradas (91,86%) que para las no quebradas (87,71%). Por otro lado, la curva COR ha obtenido un valor del 0,985, lo que indica una alta fiabilidad en el poder de clasificación del modelo. Por último, el análisis de sensibilidad realizado nos ha permitido determinar que las variables de mayor impacto han sido V4, V8 y V1 (con una importancia normalizada del 100,00%, 78,08% y 74,04%, respectivamente).

TABLA 4.11. MODELO ASIA, t-1

Ajuste del modelo	Valor
Número de neuronas en capa de entrada	11
Número de capas ocultas	1
Número de neuronas en capa oculta	5
Función de activación capa oculta	Tangente hiperbólica
Función de activación capa de salida	Softmax
Curva COR	0,985
Matriz de clasificación	%
Dentro de la muestra	86,42
Quebradas	82,63
No quebradas	88,49
Muestra de testeo	91,93
Quebradas	92,86
No quebradas	91,21
Variables	Importancia Normalizada
V1	74,01%
V2	6,91%
V3	82,56%
V4	100,00%
V5	36,35%
V6	17,04%
V7	36,11%
V8	78,08%
V9	31,74%
V10	52,39%
V11	14,38%

FIGURA 4.2. ARQUITECTURA DE LA RED. MODELO ASIA, t-1



Función de activación de capa oculta: Tangente hiperbólica

Función de activación de capa de resultado: Softmax

4.1.3. RESULTADOS MODELO EUROPA

4.1.3.1. Análisis Exploratorio

De forma similar a lo efectuado en apartados anteriores, a continuación, se presentan los resultados del análisis exploratorio correspondiente a la muestra de empresas de Europa para t-1.

En la tabla 4.12 puede observarse que las variables V1, V3, V4, V5 y V10 presentan medias con signo negativo para el caso de las empresas quebradas de la muestra. Además, que el 80% de los valores medios de las variables correspondientes a las empresas no quebradas supera al de las empresas quebradas (para el caso de la mediana, se alcanza el mismo porcentaje). Finalmente, que la desviación típica presenta valores moderados, excediendo en pocos casos los valores medios de las variables.

TABLA 4.12. ESTADÍSTICOS DESCRIPTIVOS (MODELO EUROPA, t-1)

	Media		Mediana		Desviación Típica		Mínimo		Máximo	
	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas
V1	0,039	-0,190	0,043	-0,095	0,098	0,277	-0,549	-1,095	0,274	0,331
V2	1,659	1,174	1,478	1,065	0,869	0,748	0,386	0,002	4,917	4,906
V3	0,157	-0,007	0,153	0,037	0,195	0,318	-0,342	-1,047	0,615	0,743
V4	0,082	-0,210	0,119	-0,008	0,386	0,468	-1,472	-1,987	0,710	0,333
V5	0,081	-0,132	0,070	-0,077	0,078	0,227	-0,244	-0,984	0,373	0,157
V6	1,115	1,062	1,033	0,997	0,578	0,646	0,087	0,033	3,601	3,225
V7	1,169	0,734	0,967	0,654	0,724	0,454	0,060	0,037	3,785	2,071
V8	0,187	0,363	0,178	0,357	0,149	0,246	0,000	0,000	0,603	0,983
V9	0,479	0,537	0,499	0,546	0,210	0,210	0,068	0,060	0,897	0,933
V10	0,074	-0,324	0,094	-0,122	0,288	2,372	-1,721	-8,056	0,573	8,088

En la tabla 4.13 se muestran los resultados del test de Kolmogorov-Smirnov para las empresas de la muestra relativa a Europa, con un nivel de significación del 5%. Con las excepciones de V4 y V6 para el caso de las empresas no quebradas, todas las variables son significativas al nivel del 5%. En consecuencia, no se acepta la hipótesis nula de normalidad.

TABLA 4.13. ANÁLISIS DE NORMALIDAD (MODELO EUROPA, t-1)

	NO QUEBRADAS		QUEBRADAS	
	K-S	Sig.	K-S	Sig.
V1	0,044	0,045	0,305	0,006
V2	0,217	0,003	0,255	0,000
V3	0,089	0,003	0,082	0,002
V4	0,115	0,056	0,248	0,038
V5	0,127	0,000	0,181	0,001
V6	0,058	0,086	0,257	0,059
V7	0,153	0,000	0,221	0,000
V8	0,128	0,004	0,152	0,000
V9	0,146	0,018	0,174	0,009
V10	0,249	0,000	0,323	0,000
V11	0,375	0,004	0,563	0,007

NOTA: K-S: test de Kolmogorov-Smirnov

Para las variables V5, V6, V8 y V9 se acepta la hipótesis nula de igualdad de distribuciones, conforme a los resultados de los tests de Mann-Whitney de Kolmogorov-Smirnov que aparecen en la tabla 4.14 (niveles de significación superiores al 5%). Y con las excepciones indicadas, se rechaza la hipótesis nula de igualdad en las distribuciones para el resto de las variables correspondientes a la muestra de Europa.

TABLA 4.14. TESTS NO PARAMÉTRICOS (MODELO EUROPA, t-1)

	Test de Mann-Whitney		Test de Kolmogorov-Smirnov	
	M-W	Sig.	K-S	Sig.
V1	2,475	0,042	2,278	0,041
V2	1,753	0,000	1,435	0,000
V3	1,785	0,018	0,752	0,151
V4	5,144	0,000	2,745	0,000
V5	-0,785	0,074	0,568	0,482
V6	4,288	0,152	0,365	0,048
V7	2,962	0,000	1,124	0,011
V8	0,763	0,061	0,653	0,054
V9	0,630	0,065	2,896	0,028
V10	0,631	0,000	2,054	0,000
V11	2,452	0,000	1,656	0,002

NOTA: K-S: test de Kolmogorov-Smirnov; M-W: test de Mann-Whitney

Los resultados del análisis de correlación bilateral para la muestra correspondiente a Europa en t-1 (tabla 4.15) detectan una elevada relación entre las variables V1 y V5, que presentan, en concreto, un coeficiente de correlación de Pearson de 0,936. Asimismo, la correlación es elevada entre las parejas V3 y V7 (0,670) y V2 y V7 (0,643). Haciendo balance del análisis exploratorio realizado, es posible concluir que todas las variables consideradas, a excepción de la variable V11, muestran signos de ser variables relevantes para el proyectado análisis de quiebra.

TABLA 4.15. ANÁLISIS DE CORRELACIÓN BILATERAL (MODELO EUROPA, t-1)

	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11	Quiebra
V1	1	0,263**	0,492**	0,556**	0,936**	0,111	0,329**	-0,348**	0,128	0,180*	-0,151	-0,499**
V2	0,263**	1	0,430**	0,142	0,279**	-0,096	0,643**	-0,230**	0,205**	-0,118	0,050	-0,307**
V3	0,492**	0,430**	1	0,399**	0,465**	-0,043	0,670**	-0,475**	0,494**	-0,112	-0,077	-0,309**
V4	0,556**	0,142	0,399**	1	0,578**	0,111	0,263**	-0,287**	0,188*	0,099	-0,162*	-0,350**
V5	0,936**	0,279**	0,465**	0,578**	1	0,109	0,296**	-0,250**	0,089	0,223**	-0,190*	-0,508**
V6	0,111	-0,096	-0,043	0,111	0,109	1	-0,171*	-0,031	0,375**	0,113	-0,139	-0,028
V7	0,329**	0,643**	0,670**	0,263**	0,296**	-0,171*	1	-0,478**	0,245**	0,005	0,151	-0,355**
V8	-0,348**	-0,230**	-0,475**	-0,287**	-0,250**	-0,031	-0,478**	1	-0,063	0,049	-0,134	0,392**
V9	0,128	0,205**	0,494**	0,188*	0,089	0,375**	0,245**	-0,063	1	-0,083	-0,163*	0,078
V10	0,180*	-0,118	-0,112	0,099	0,223**	0,113	0,005	0,049	-0,083	1	-0,094	-0,125
V11	-0,151	0,050	-0,077	-0,162*	-0,190*	-0,139	0,151	-0,134	-0,163*	-0,094	1	0,000
Quiebra	-0,499**	-0,307**	-0,309**	-0,350**	-0,508**	-0,028	-0,355**	0,392**	0,078	-0,125	0,000	1

**Correlación significativa a nivel 0,01 (bilateral)

*Correlación significativa a nivel 0,05 (bilateral)

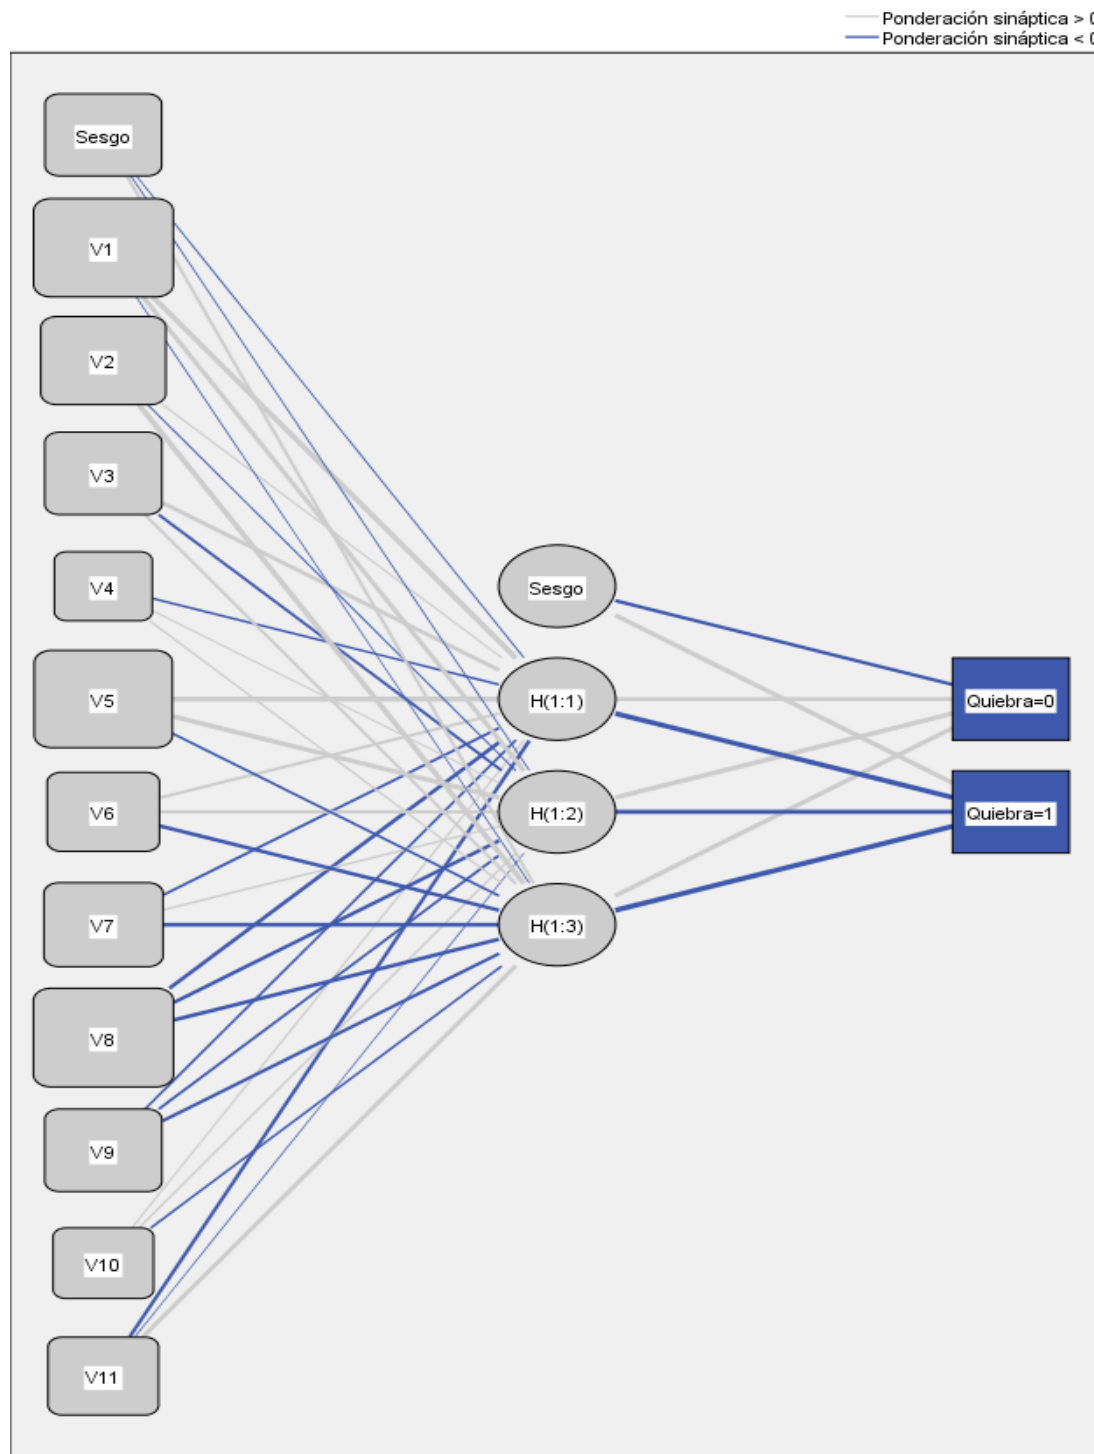
4.1.3.2. Análisis Confirmatorio

En la tabla 4.16 y en la figura 4.3 se muestran los resultados del modelo regional obtenido con la muestra de empresas pertenecientes a Europa en t-1. El modelo está compuesto por una capa de entrada con 11 neuronas, una capa oculta con 3 neuronas y una capa de salida con 2 neuronas. Con esta estructura de red, el nivel de clasificación obtenido dentro de la muestra asciende al 88,44%, clasificándose correctamente el 91,85% las empresas no quebradas y el 83,76% de las quebradas. Por su parte, en la muestra de testeo, el nivel de clasificación ha ascendido al 92,57%, obteniendo mayor acierto con las empresas no quebradas (94,05%) que con las empresas quebradas (90,57%). La tabla 4.16 informa, además, del alto valor obtenido por la curva COR (0,934) y de las variables de mayor impacto en el modelo (V8, V1 y V5, con una importancia normalizada del 100,00%, 98,98% y 95,89%, respectivamente).

TABLA 4.16. MODELO EUROPA, t-1

Ajuste del modelo	Valor
Número de neuronas en capa de entrada	11
Número de capas ocultas	1
Número de neuronas en capa oculta	3
Función de activación capa oculta	Tangente hiperbólica
Función de activación capa de salida	Softmax
Curva COR	0,934
Matriz de clasificación	%
Dentro de la muestra	88,44
Quebradas	83,76
No quebradas	91,85
Muestra de testeo	95,26
Quebradas	92,57
No quebradas	96,05
Variables	Importancia Normalizada
V1	98,98%
V2	67,50%
V3	50,87%
V4	9,58%
V5	95,89%
V6	40,52%
V7	55,15%
V8	100,00%
V9	60,79%
V10	15,02%
V11	36,66%

FIGURA 4.3. ARQUITECTURA DE LA RED. MODELO EUROPA, t-1



Función de activación de capa oculta: Tangente hiperbólica

Función de activación de capa de resultado: Softmax

4.1.4. RESULTADOS MODELO AMÉRICA

4.1.4.1. Análisis Exploratorio

En este apartado se realiza el análisis exploratorio para la muestra de empresas pertenecientes a la región América, con información correspondientes al período t-1.

En la tabla 4.17 se presentan los resultados del análisis descriptivo realizado. Se comprueba que todas las variables presentan valores medios de signo positivo, tanto en empresas quebradas como en no quebradas. Además, que el 80% de los valores medios de las variables de las empresas no quebradas son superiores al de las empresas quebradas. Un comportamiento similar se verifica para los valores de la mediana en toda la muestra. De otra parte, también se aprecia valores moderados de la desviación típica, exceptuando las variables V5 y V10 en el grupo de empresas no quebradas.

TABLA 4.17. ESTADÍSTICOS DESCRIPTIVOS (MODELO AMÉRICA, t-1)

	Media		Mediana		Desviación Típica		Mínimo		Máximo	
	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas
V1	0,037	0,070	0,037	-0,109	-0,254	0,439	-0,302	-2,433	0,289	0,443
V2	2,257	1,142	2,084	1,101	1,609	1,874	0,454	0,074	5,752	11,342
V3	0,225	0,187	0,214	0,036	0,099	0,216	-0,269	-236,000	0,670	0,906
V4	0,605	0,557	0,188	-0,384	-1,696	9,012	156,000	-372,000	1,563	1,908
V5	0,080	0,096	0,077	-0,022	-27,605	0,327	-0,396	-20,640	0,509	0,172
V6	1,079	0,679	0,904	0,962	1,107	0,820	0,209	0,000	3,021	3,537
V7	1,329	0,828	1,157	0,562	1,03	1,738	0,086	0,042	3,840	10,632
V8	0,261	0,188	0,253	0,399	0,504	0,485	0,000	0,000	0,828	2,365
V9	0,434	0,217	0,431	0,383	0,422	0,24	0,033	0,016	0,829	1,050
V10	0,150	0,395	0,067	0,035	-316,325	8,818	-0,278	-43,480	3,049	13,344

En la tabla 4.18 se exponen los resultados del test de Kolmogorov-Smirnov para la muestra de la región América a un nivel de significación del 5%. Con la excepción de V10 para el caso de las empresas no quebradas, todas las variables presentan significación a dicho nivel, por lo que se rechaza la hipótesis nula de normalidad.

TABLA 4.18. ANÁLISIS DE NORMALIDAD (MODELO AMÉRICA, t-1)

	NO QUEBRADAS		QUEBRADAS	
	K-S	Sig.	K-S	Sig.
V1	0,021	0,015	0,075	0,000
V2	0,174	0,024	0,117	0,014
V3	0,004	0,000	0,027	0,000
V4	0,268	0,002	0,194	0,000
V5	0,137	0,000	0,139	0,000
V6	0,298	0,000	0,246	0,005
V7	0,383	0,000	0,183	0,000
V8	0,123	0,000	0,084	0,000
V9	0,102	0,012	0,057	0,006
V10	0,025	0,084	0,019	0,034
V11	0,046	0,000	0,156	0,000

NOTA: K-S: test de Kolmogorov-Smirnov

Según los resultados que aparecen en la tabla 4.19, se acepta la hipótesis nula de igualdad de distribuciones para V10 y se rechaza dicha hipótesis nula para el resto de las variables.

TABLA 4.19 TESTS NO PARAMÉTRICOS (MODELO AMÉRICA, t-1)

	Test de Mann-Whitney		Test de Kolmogorov-Smirnov	
	M-W	Sig.	K-S	Sig.
V1	1,655	0,002	1,528	0,000
V2	2,853	0,041	0,855	0,000
V3	0,735	0,028	2,612	0,014
V4	1,181	0,003	0,185	0,000
V5	0,681	0,046	0,746	0,015
V6	3,863	0,000	0,872	0,000
V7	0,895	0,000	0,074	0,000
V8	1,823	0,000	0,693	0,008
V9	0,720	0,000	0,874	0,000
V10	1,683	0,881	0,098	0,801
V11	2,953	0,004	2,987	0,000

NOTA: K-S: test de Kolmogorov-Smirnov; M-W: test de Mann-Whitney

Los resultados del análisis de correlación bilateral para la muestra correspondiente a la región América en t-1 (tabla 4.20) detectan una elevada correlación entre las variables V2 y V7, que presentan, en concreto, un coeficiente de correlación de Pearson de 0,904. De igual forma, la correlación es elevada entre V3 y V5 (0,756).

TABLA 4.20. ANÁLISIS DE CORRELACIÓN BILATERAL (MODELO AMÉRICA, t-1)

	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11	Quiebra
V1	1	0,325**	0,682**	0,023	0,570**	0,033	0,223**	-0,684**	0,020	0,158*	-0,130	-0,458**
V2	0,325**	1	0,186*	-0,430**	0,126	-0,138	0,904**	-0,381**	0,392**	0,045	0,104	-0,236**
V3	0,682**	0,186*	1	0,050	0,756**	0,058	0,130	-0,697**	-0,001	-0,037	-0,065	-0,162*
V4	0,023	-0,430**	0,050	1	0,048	0,116	-0,553**	0,058	-0,202**	-0,013	-0,132	-0,093
V5	0,570**	0,126	0,756**	0,048	1	0,073	0,088	-0,380**	-0,022	-0,025	0,029	-0,109
V6	0,033	-0,138	0,058	0,116	0,073	1	-0,244**	-0,060	0,425**	-0,051	-0,108	0,036
V7	0,223**	0,904**	0,130	-0,553**	0,088	-0,244**	1	-0,287**	0,277**	0,012	0,114	-0,134
V8	-0,684**	-0,381**	-0,697**	0,058	-0,380**	-0,060	-0,287**	1	-0,314**	-0,075	-0,030	0,328**
V9	0,020	0,392**	-0,001	-0,202**	-0,022	0,425**	0,277**	-0,314**	1	-0,029	0,209**	-0,004
V10	0,158*	0,045	-0,037	-0,013	-0,025	-0,051	0,012	-0,075	-0,029	1	0,061	-0,231**
V11	-0,130	0,104	-0,065	-0,132	0,029	-0,108	0,114	-0,030	0,209**	0,061	1	0,000
Quiebra	-0,458**	-0,236**	-0,162*	-0,090	-0,109	0,036	-0,134	0,328**	-0,004	-0,231**	0,000	1

**Correlación significativa a nivel 0,01 (bilateral)

*Correlación significativa a nivel 0,05 (bilateral)

Conforme al análisis exploratorio realizado, es posible concluir que prácticamente todas las variables, exceptuando la V11, muestran signos de ser relevantes para el análisis de quiebra perseguido.

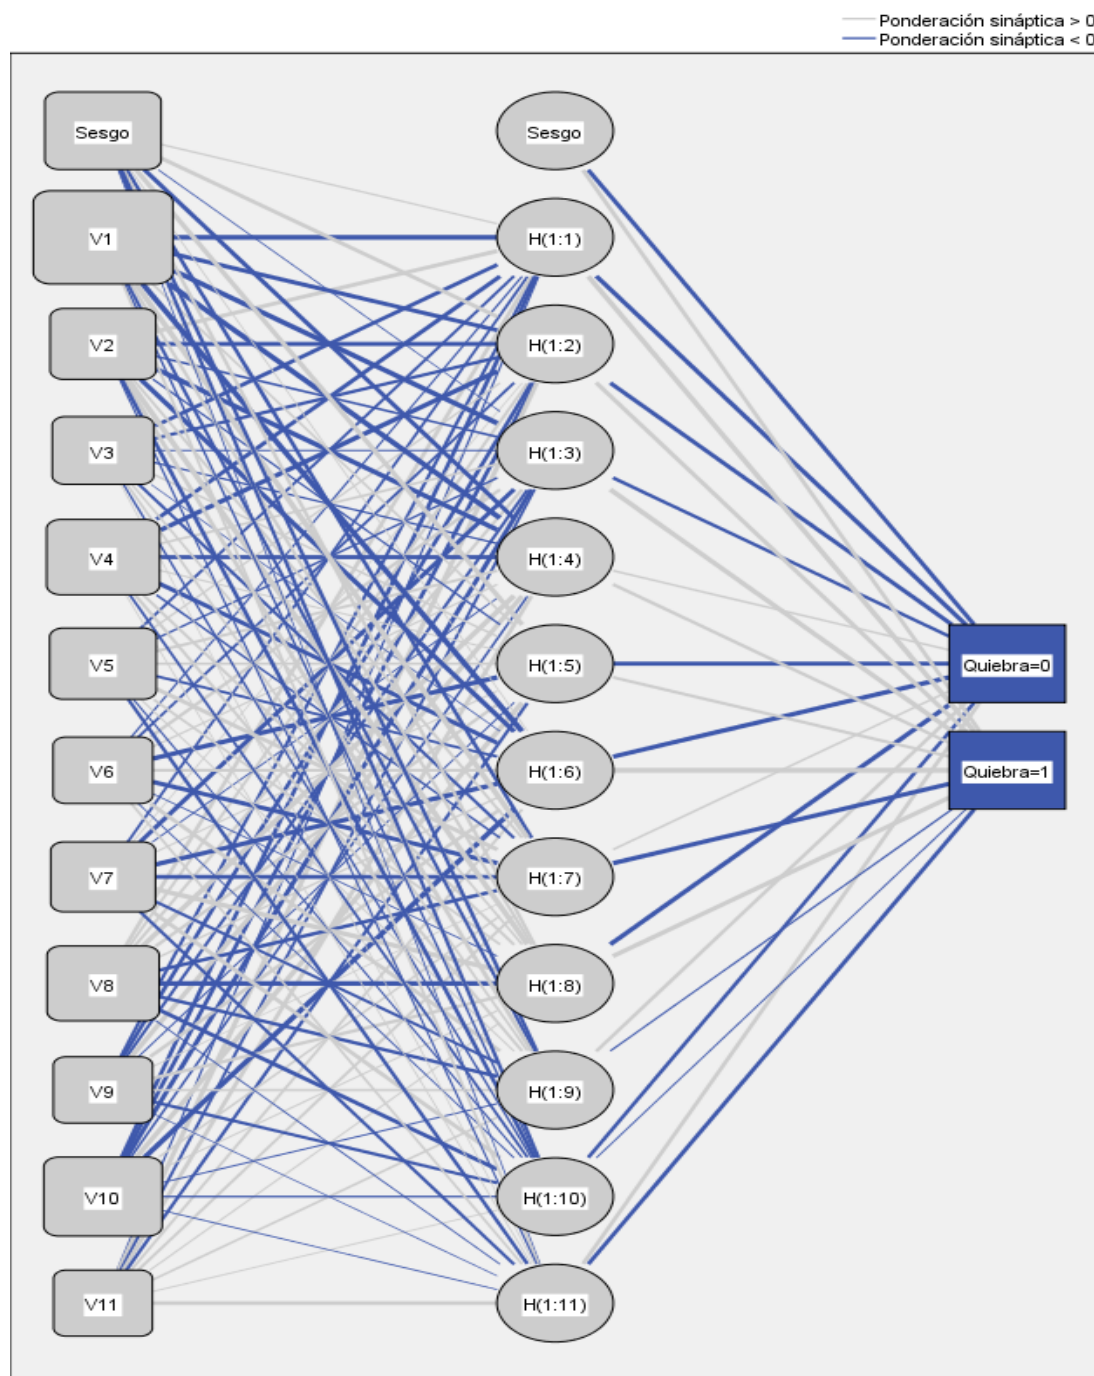
4.1.4.2. Análisis Confirmatorio

Los resultados del modelo PMC obtenido para la muestra de América en t-1 aparecen en la tabla 4.21. El modelo está constituido por una capa de entrada con 11 neuronas, una capa oculta también con 11 neuronas, y una capa de salida con 2 neuronas. El nivel de clasificación obtenido dentro de la muestra asciende al 83,93%, clasificándose correctamente el 86,67% las empresas no quebradas y el 82,38% de las quebradas. En la muestra de testeo, el nivel de clasificación ha ascendido al 87,23%, prediciendo con mayor acierto entre las empresas no quebradas (90,31%) que entre las empresas quebradas (85,19%). Por otro lado, la curva COR ha obtenido un valor del 0,923, y el análisis de sensibilidad realizado nos ha permitido determinar que las variables de mayor impacto han sido V3, V5 y V10 (con una importancia normalizada del 100,00%, 69,51% y 54,56%, respectivamente).

TABLA 4.21 MODELO AMÉRICA, t-1

Ajuste del modelo	Valor
Número de neuronas en capa de entrada	11
Número de capas ocultas	1
Número de neuronas en capa oculta	11
Función de activación capa oculta	Tangente hiperbólica
Función de activación capa de salida	Softmax
Curva COR	0,923
Matriz de clasificación	%
Dentro de la muestra	83,93
Quebradas	82,38
No quebradas	86,67
Muestra de testeo	89,36
Quebradas	88,19
No quebradas	91,31
Variables	Importancia Normalizada
V1	17,76%
V2	27,51%
V3	100,00%
V4	42,69%
V5	69,51%
V6	53,92%
V7	24,93%
V8	41,06%
V9	13,30%
V10	54,56%
V11	12,42%

FIGURA 4.4. ARQUITECTURA DE LA RED. MODELO AMÉRICA, t-1



Función de activación de capa oculta: Tangente hiperbólica

Función de activación de capa de resultado: Softmax

4.1.5. COMPARACIÓN DEL MODELO GLOBAL CON LOS MODELOS REGIONALES EN $t-1$.

Una vez estimados los modelos globales y regionales con información correspondiente a $t-1$ procede contrastar la hipótesis H_1 , formulada en el capítulo primero de esta tesis. Esta hipótesis planteaba si un modelo global, obtenido con una muestra de empresas de las tres regiones representadas en este estudio, era igual o distinto a los modelos regionales estimados a partir de muestras de cada una de las regiones incorporadas en el presente trabajo.

Para el contraste de esta hipótesis se utilizarán los resultados que aparecen en la tabla 4.22. Como puede comprobarse, de la comparación de los modelos estimados es posible concluir que los conjuntos de variables seleccionados por los mismos son distintos. En consecuencia, la hipótesis H_1 es aceptada, pues los modelos globales y regionales obtenidos para las muestras correspondientes a $t-1$ son diferentes.

TABLA 4.22. MODELOS GLOBAL Y REGIONALES, t-1

Ajuste del Modelo	Global	Asia	Europa	América
Número de neuronas en capa de entrada	11	11	11	11
Número de capas ocultas	7	5	3	11
Número de neuronas en capa oculta	2	2	2	2
Curva COR	0,902	0,985	0,934	0,923
Matriz de Clasificación (%)				
Fuera de la Muestra				
No quebradas	90,76	91,21	96,05	91,31
Quebradas	86,73	92,86	92,57	88,19
Total	88,79	91,93	95,26	89,35
Predictores	V3	V1	V1	V3
	V5	V3	V2	V5
	V8	V4	V3	V6
	V9	V8	V5	V10
	V10	V10	V7	
			V8	
			V9	

NOTA: Predictores con un impacto normalizado $\geq 50\%$

4.1.6. MODELO CON VARIABLE REGIONAL

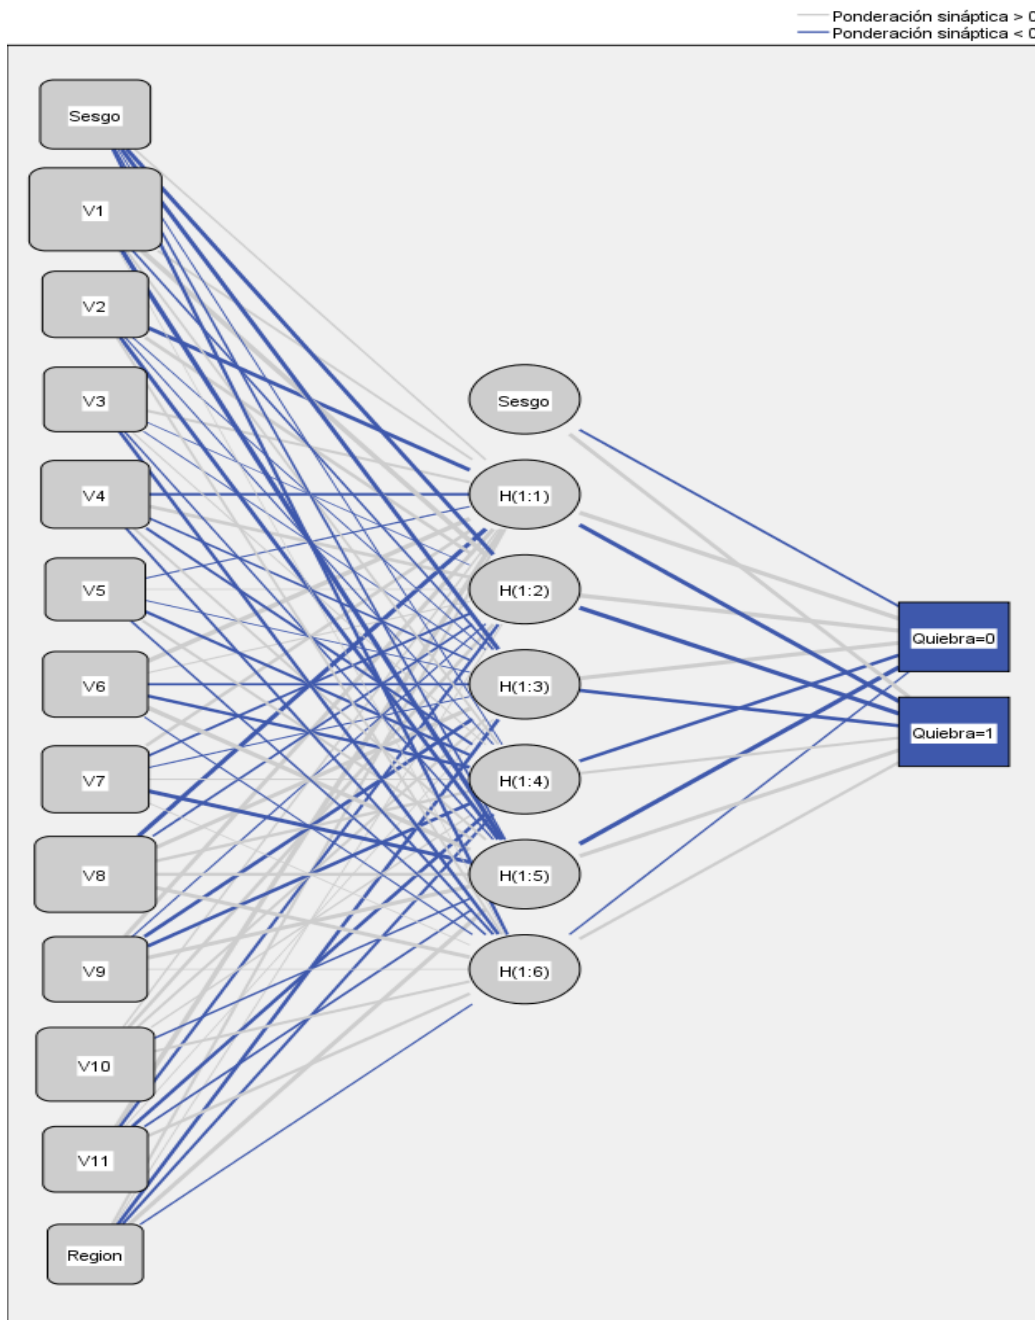
Con objeto de testar la segunda hipótesis de investigación, que cuestionaba la superioridad de un modelo global sin una variable que recoje la distinción entre regiones frente a un modelo que incluyera este tipo de variables, se estimará un nuevo modelo global incluyendo en el mismo una variable regional.

En la tabla 4.23 y en la figura 4.5 se muestran los resultados del modelo global construido con variable regional. El nivel de clasificación obtenido dentro de la muestra asciende al 88,79% y con la muestra de testeo al 94,33%. El valor de la curva COR asciende al 0,938 y las variables de mayor impacto son V3, V9 y V5 (con una importancia normalizada del 100,00%, 76,90% y 76,20%, respectivamente).

TABLA 4.23. MODELO GLOBAL CON VARIABLE REGIONAL, t-1

Ajuste del modelo		Valor
Número de neuronas en capa de entrada		12
Número de capas ocultas		1
Número de neuronas en capa oculta		6
Función de activación capa oculta		Tangente hiperbólica
Función de activación capa de salida		Softmax
Curva COR		0,938
Matriz de clasificación		%
Dentro de la muestra		88,79
Quebradas		86,73
No quebradas		90,76
Muestra de testeo		94,33
Quebradas		92,64
No quebradas		95,38
Variables		Importancia Normalizada
V1		33,20%
V2		39,60%
V3		100,00%
V4		45,30%
V5		76,20%
V6		37,30%
V7		41,90%
V8		44,30%
V9		76,90%
V10		35,50%
V11		27,30%
REGIÓN		56,20%

**FIGURA 4.5. ARQUITECTURA DE LA RED. MODELO GLOBAL CON
VARIABLE REGIONAL, $t-1$**



Función de activación de capa oculta: Tangente hiperbólica

Función de activación de capa de resultado: Softmax

Una vez estimado y analizado el modelo global con la variable regional, procede compararlo con el modelo global obtenido sin la inclusión de la variable regional. Para llevar a cabo esta comparación se han utilizado los criterios de Akaike, de Schwartz y de Hannan-Quinn. Como se comentó al final del capítulo 2 de la presente tesis, la regla de decisión para los tres criterios es la misma: el mejor modelo es el que ofrece el menor valor en la comparación. De acuerdo con esta regla se ha podido constatar que el modelo global con variable regional es superior al modelo global estimado sin dicha variable (Tabla 4.24). De esta forma, queda aceptada también la hipótesis H_2 para los modelos estimados con información de $t-1$ y, por tanto, la inclusión de la variable regional enriquece y aumenta la capacidad de explicación y predicción del modelo global.

TABLA 4.24. COMPARACIÓN DE MODELOS GLOBALES, t-1.

Ajuste del Modelo	Global	Global
	SIN VARIABLE REGIONAL	CON VARIABLE REGIONAL
Número de neuronas en capa de entrada	11	12
Número de capas ocultas	1	1
Número de neuronas en capa oculta	7	11
Curva COR	0,902	0,938
Matriz de Clasificación (%)		
Fuera de la Muestra		
No quebradas	90,76	95,38
Quebradas	86,73	92,64
Total	88,79	94,33
Criterio de Akaike	213,537	101,385
Criterio de Schwartz	224,054	118,542
Criterio de Hannan-Quinn	218,396	104,258

4.1.7. ANÁLISIS DE ROBUSTEZ

En este apartado se llevará a cabo un análisis de la robustez de los resultados obtenidos en los diferentes modelos. Este análisis se organiza en dos partes: por un lado, se ofrecerán los resultados de una validación cruzada (VC) de los modelos y se comprobará la capacidad del modelo global con la variable regional para conseguir buenos resultados utilizando las muestras de cada una de las regiones. Por otro lado, se aplicarán a los distintos modelos obtenidos los criterios de Akaike, de Schwartz y de Hannan-Quinn. Este análisis de robustez nos permitirá contrastar la hipótesis H_3 , es decir, si el modelo global

con variable regional puede predecir correctamente con las muestras de las diferentes regiones.

VC es uno de los métodos más aplicados para valorar la precisión predictiva de un modelo (Allen, 1974; Stone, 1974; Geisser, 1975). En esencia, consiste en dividir los datos muestrales, en los que una parte de los mismos se usan en la construcción de cada modelo, y el resto para calcular la precisión de los modelos estimados por medio de la evaluación de los errores de validación. Como resultado de este proceso resultaría seleccionado el modelo con el mejor rendimiento global (Zhang y Yan, 2015). El método VC se ha empleado extensamente en la minería de datos, bien sea para la selección de un modelo entre distintas opciones, o como un procedimiento para seleccionar la forma más funcional del modelo (Hastie et al., 2009).

Las tablas 4.25 y 4.26 informan de la VC del modelo global con la variable regional en las diferentes muestras regionales. A tenor de lo que indican los diferentes criterios de selección (el criterio de Akaike, el criterio de Schwartz y el criterio de Hannan-Quinn), el modelo global con la variable regional es capaz de predecir con éxito en las muestras regionales. Por tanto, la hipótesis H_3 queda aceptada.

TABLA 4.25. RESULTADOS DE LOS MODELOS GLOBALES Y REGIONALES, t-1

Ajuste del Modelo	Global	Asia	Europa	América
Número de neuronas en capa de entrada	12	11	11	11
Número de capas ocultas	1	1	1	1
Número de neuronas en capa oculta	6	5	3	11
Curva COR	0,938	0,985	0,934	0,923
Matriz de Clasificación (%)				
Fuera de la Muestra				
No quebradas	88,38	91,21	96,05	91,31
Quebradas	92,45	92,86	92,57	88,19
Total	90,11	91,93	95,26	89,35
Criterio de Akaike	101,385	14,637	34,765	37,832
Criterio de Schwartz	118,542	26,812	54,924	51,185
Criterio de Hannan-Quinn	104,258	18,259	43,862	40,932

TABLA 4.26 ROBUSTEZ DEL MODELO GLOBAL CON VARIABLE REGIONAL, t-1

Ajuste del Modelo	Asia	Europa	América
Número de neuronas en capa de entrada	5	5	5
Número de capas ocultas	1	1	1
Número de neuronas en capa oculta	4	3	7
Curva COR	0,989	0,965	0,952
Matriz de Clasificación (%)			
Fuera de la Muestra			
No quebradas	96,85	93,08	86,72
Quebradas	94,12	95,74	92,59
Total	95,74	97,13	89,72
Criterio de Akaike	11,148	32,562	33,238
Criterio de Schwartz	22,289	47,432	48,157
Criterio de Hannan-Quinn	15,865	42,985	37,630

4.2. RESULTADOS PARA t-2

4.2.1. MODELO GLOBAL

4.2.1.1. Análisis Exploratorio

A continuación, se procede al análisis descriptivo de los parámetros estadísticos más importantes, a la aplicación de tests paramétricos o no paramétricos y al análisis de correlación de las variables obtenidas con información en t-2.

En la tabla 4.29 se presentan los resultados del análisis descriptivo efectuado para la muestra global con datos relativos a t-2. Se puede comprobar que todas las variables presentan valores medios con signo positivo. Además, que el 50% de los valores medios correspondientes a las empresas no quebradas superan al de las empresas quebradas (sólo las variables V1, V3, V4, V5 y V10 presentan medias y medianas inferiores en las empresas no quebradas respecto a las quebradas). Por su parte, la desviación típica de las variables V4 y V10 presentan valores más dispersos que los del resto de variables.

TABLA 4.29. ESTADÍSTICOS DESCRIPTIVOS (MODELO GLOBAL, t-2)

	Media		Mediana		Desviación Típica		Mínimo		Máximo	
	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas
V1	0,033	0,105	0,021	0,055	-0,133	0,334	-0,744	-9,234	5,153	2,025
V2	2,024	1,487	1,575	0,873	1,586	1,589	-2,049	-2,754	24,082	57,984
V3	0,200	0,208	0,148	0,164	0,101	0,284	0,027	-0,062	0,914	0,986
V4	0,106	0,556	0,048	0,347	-2,282	26,220	-2,770	-7,711	5,272	2,719
V5	0,072	0,091	0,039	0,052	-0,071	0,240	-9,115	-2,847	2,468	3,190
V6	1,095	0,613	0,658	0,362	1,013	0,693	-4,653	-1,853	4,976	5,617
V7	1,296	0,961	0,742	0,470	1,036	1,418	-3,157	-2,141	6,458	2,141
V8	0,230	0,179	0,167	0,081	0,371	0,297	0,009	-0,480	1,541	0,812
V9	0,491	0,215	0,317	0,158	0,525	0,233	-0,581	-0,284	1,283	0,849
V10	0,105	0,304	0,060	0,199	-1,204	16,945	-2,842	-5,632	0,752	1,248

Como se puede observar en la tabla 4.30, todas las variables presentan un nivel de significación inferior al 5%. En consecuencia, se rechaza la hipótesis nula de normalidad.

TABLA 4.30. ANÁLISIS DE NORMALIDAD (MODELO GLOBAL, t-2)

	No quebradas		Quebradas	
	K-S	Sig,	K-S	Sig,
V1	0,257	0,000	0,243	0,000
V2	0,121	0,000	0,138	0,000
V3	0,489	0,000	0,534	0,000
V4	0,176	0,000	0,182	0,000
V5	0,483	0,000	0,510	0,000
V6	0,174	0,012	0,169	0,000
V7	0,178	0,000	0,165	0,004
V8	0,138	0,000	0,147	0,000
V9	0,077	0,000	0,064	0,000
V10	0,504	0,000	0,478	0,000
V11	0,318	0,000	0,295	0,000

NOTA: K-S: test de Kolmogorov-Smirnov

Conforme a los resultados que aparecen en la tabla 4.31, se rechaza la hipótesis nula en prácticamente la totalidad de las variables, con la excepción de V7.

TABLA 4.31 TESTS NO PARAMÉTRICOS (MODELO GLOBAL, t-2)

	Test de Mann-Whitney		Test de Kolmogorov-Smirnov	
	M-W	Sig.	K-S	Sig.
V1	21,863	0,000	12,138	0,000
V2	11,856	0,000	5,387	0,000
V3	-5,271	0,000	3,162	0,000
V4	18,296	0,000	9,507	0,000
V5	5,178	0,000	2,291	0,000
V6	10,651	0,000	5,346	0,000
V7	-9,254	0,067	5,037	0,005
V8	-2,892	0,017	1,389	0,073
V9	1,051	0,000	5,215	0,000
V10	2,859	0,008	1,485	0,000

NOTA: K-S: test de Kolmogorov-Smirnov; M-W: test de Mann-Whitney

Para finalizar el análisis exploratorio, se procederá al cálculo de las correlaciones entre las variables. A tal fin la tabla 4.32 muestra los coeficientes de correlación bilateral en la muestra global con datos de t-2. Los resultados indican que existe una elevada correlación entre las variables V2 y V7, con un coeficiente de correlación de Pearson de 0,898, así como en V1 y V5 (0,860).

TABLA 4.32 ANÁLISIS DE CORRELACIÓN BILATERAL (MODELO GLOBAL, t-2)

	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11	Quiebra
V1	1	-0,068	0,071	0,284**	0,860**	0,133**	-0,173**	-0,212**	-0,027	0,046	-0,157**	-0,322**
V2	-0,068	1	0,702**	-0,503**	0,010	-0,118*	0,898**	-0,270**	0,349**	0,045	0,101*	-0,141**
V3	0,071	0,702**	1	-0,154**	0,087	-0,033	0,579**	-0,419**	0,601**	0,174**	0,088	-0,196**
V4	0,284**	-0,503**	-0,154**	1	0,188**	0,087	-0,674**	0,035	-0,109*	0,005	-0,081	-0,064
V5	0,860**	0,010	0,087	0,188**	1	0,168**	-0,078	-0,200**	-0,045	0,031	-0,199**	-0,368**
V6	0,133**	-0,118*	-0,033	0,087	0,168**	1	-0,181**	-0,102*	0,291**	0,049	-0,143**	-0,062
V7	-0,173**	0,898**	0,579**	-0,674**	-0,078	-0,181**	1	-0,285**	0,279**	0,039	0,177**	-0,107*
V8	-0,212**	-0,270**	-0,419**	0,035	-0,200**	-0,102*	-0,285**	1	-0,226**	-0,089	-0,079	0,278**
V9	-0,027	0,349**	0,601**	-0,109*	-0,045	0,291**	0,279**	-0,226**	1	0,060	0,065	0,075
V10	0,046	0,045	0,174**	0,005	0,031	0,049	0,039	-0,089	0,060	1	0,007	-0,055
V11	-0,157**	0,101*	0,088	-0,081	-0,199**	-0,143**	0,177**	-0,079	0,065	0,007	1	-0,001
Quiebra	-0,322**	-0,141**	-0,196**	-0,064	-0,368**	-0,062	-0,107*	0,278**	0,075	-0,055	-0,001	1

**Correlación significativa a nivel 0,01 (bilateral)

*Correlación significativa a nivel 0,05 (bilateral)

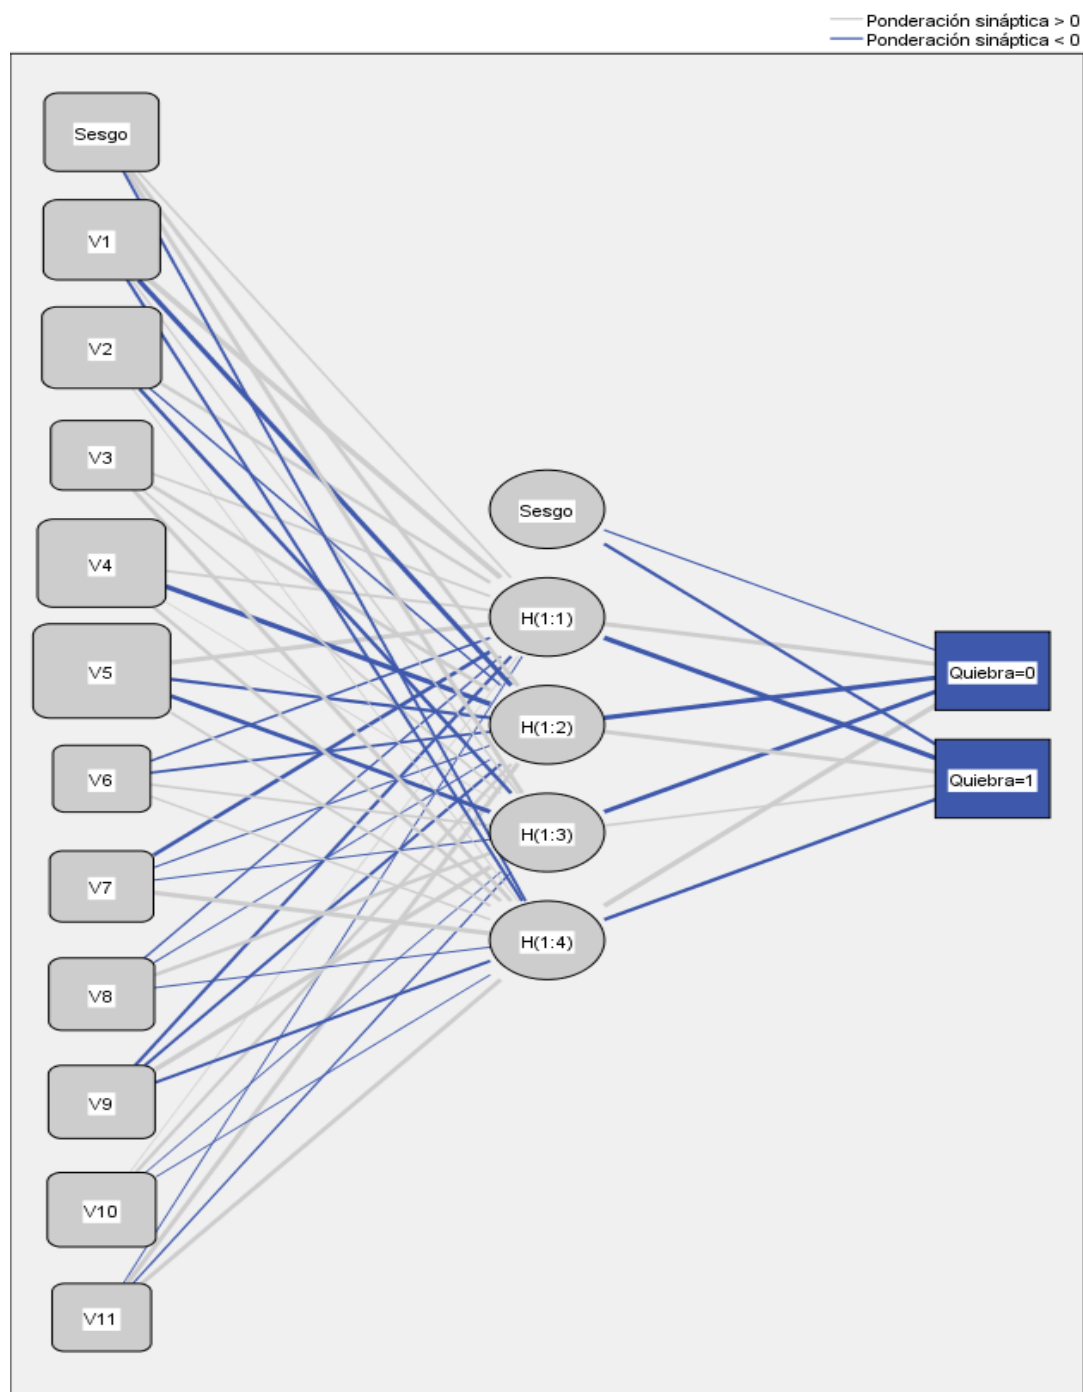
4.2.1.2. Análisis Confirmatorio

En la tabla 4.33 y en la figura 4.5 se muestran los resultados del modelo global con información de t-2. El modelo tiene una estructura compuesta por una capa de entrada con 11 neuronas, una capa oculta con 4 neuronas y una capa de salida con 2 neuronas. El nivel de clasificación obtenido dentro de la muestra asciende al 80,16%, clasificándose correctamente el 75,28% las empresas quebradas y el 84,53% de las no quebradas. Al generalizar el modelo en la muestra de testeo, el nivel de clasificación ha ascendido al 85,62%, prediciendo con mayor acierto entre las empresas quebradas (82,65%). Además, la curva COR ha obtenido un valor del 0,898 y el análisis de sensibilidad ha permitido determinar que las variables de mayor impacto han sido V5, V4 y V8 (con una importancia normalizada del 100,00%, 79,72% y 69,90%, respectivamente).

TABLA 4.33. MODELO GLOBAL, t-2

Ajuste del modelo	Valor
Número de neuronas en capa de entrada	11
Número de capas ocultas	1
Número de neuronas en capa oculta	4
Función de activación capa oculta	Tangente hiperbólica
Función de activación capa de salida	Softmax
Curva COR	0,898
Matriz de clasificación	%
Dentro de la muestra	80,16
Quebradas	75,28
No quebradas	84,53
Muestra de testeo	85,62
Quebradas	82,65
No quebradas	89,12
Variables	Importancia Normalizada
V1	55,06%
V2	60,05%
V3	21,59%
V4	79,72%
V5	100,00%
V6	12,93%
V7	26,23%
V8	69,90%
V9	52,63%
V10	36,55%
V11	16,02%

FIGURA 4.5. ARQUITECTURA DE LA RED. MODELO GLOBAL, t-2



Función de activación de capa oculta: Tangente hiperbólica

Función de activación de capa de resultado: Softmax

4.2.2. RESULTADOS MODELO ASIA

4.2.2.1 Análisis Exploratorio

En este apartado se aborda el análisis exploratorio de las variables correspondientes a la muestra de la región Asia con información correspondiente a t-2.

Los resultados que aparecen en la tabla 4.34 indican que los valores medios de las variables V1, V3, V4, V5 y V10 muestran signo positivo para las empresas quebradas. Además, que la variable V8 presenta una media inferior en el caso de las empresas no quebradas, y que las desviaciones típicas de todas las variables no presentan valores con una significativa dispersión.

TABLA 4.34. ESTADÍSTICOS DESCRIPTIVOS. MODELO ASIA, t-2

	Media		Mediana		Desviación Típica		Mínimo		Máximo	
	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas
V1	0,032	-0,210	0,019	0,008	0,027	0,158	-0,685	-7,891	5,232	1,598
V2	1,640	0,983	1,483	0,742	0,689	0,468	-2,586	-2,265	5,896	5,180
V3	0,194	-0,138	0,146	-0,082	0,150	0,236	0,015	-0,083	1,162	0,914
V4	0,229	-0,268	0,083	-0,144	0,196	0,257	-2,157	-2,716	5,155	2,165
V5	0,055	-0,043	0,047	0,022	0,039	0,129	-1,124	-2,754	2,165	3,876
V6	1,123	1,039	0,729	0,355	0,555	0,442	-3,152	-1,745	4,428	5,891
V7	1,145	0,665	0,863	0,515	0,563	0,476	-2,745	-2,075	5,982	2,879
V8	0,243	0,549	0,157	0,415	0,165	0,224	0,017	-0,586	1,981	0,865
V9	0,572	0,562	0,354	0,382	0,177	0,217	-0,448	-0,177	1,784	1,298
V10	0,073	-0,498	0,028	-0,261	0,075	0,628	-0,326	-2,789	0,816	1,985

En la tabla 4.35 se muestran los resultados del test de Kolmogorov-Smirnov. Con la excepción de V9 para el caso de las empresas no quebradas, todas las variables presentan un nivel de significación inferior al 5%. Por tanto, se rechaza la hipótesis nula de normalidad.

TABLA 4.35 ANÁLISIS DE NORMALIDAD. MODELO ASIA, t-2

	NO QUEBRADAS		QUEBRADAS	
	K-S	Sig.	K-S	Sig.
V1	0,154	0,000	0,318	0,000
V2	0,275	0,000	0,286	0,002
V3	0,168	0,032	0,087	0,011
V4	0,127	0,000	0,238	0,000
V5	0,196	0,000	0,176	0,000
V6	0,284	0,000	0,251	0,000
V7	0,141	0,000	0,229	0,003
V8	0,148	0,000	0,150	0,009
V9	0,137	0,058	0,168	0,018
V10	0,224	0,007	0,308	0,000
V11	0,539	0,000	0,513	0,000

NOTA: K-S: test de Kolmogorov-Smirnov

Según los resultados obtenidos tras el empleo de tests no paramétricos, se acepta la hipótesis nula de igualdad de distribuciones para V3, V5 y V8 (tabla 4.36).

TABLA 4.36 TESTS NO PARAMÉTRICOS. MODELO ASIA, t-2

	Test de Mann-Whitney		Test de Kolmogorov-Smirnov	
	M-W	Sig.	K-S	Sig.
V1	3,425	0,000	3,475	0,000
V2	-4,634	0,000	2,462	0,000
V3	1,737	0,062	1,771	0,122
V4	5,317	0,000	3,532	0,000
V5	-0,256	0,715	0,707	0,748
V6	-3,428	0,000	2,162	0,000
V7	3,211	0,001	1,514	0,002
V8	0,270	0,459	0,778	0,587
V9	0,749	0,000	2,904	0,000
V10	5,863	0,000	2,879	0,000
V11	-2,372	0,000	3,864	0,000

NOTA: K-S: test de Kolmogorov-Smirnov; M-W: test de Mann-Whitney

Por su parte, la tabla 4.37 muestra los resultados del análisis de correlación bilateral. Se comprueba que existe una elevada correlación entre las variables V2 y V7 (coeficiente de correlación de Pearson de 0,890), las variables V1 y V5 (0,858), así como V2 y V3 (0,834).

TABLA 4.37. ANÁLISIS DE CORRELACIÓN BILATERAL. MODELO ASIA, t-2

	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11	Quiebra
V1	1	0,330**	0,432**	0,706**	0,858**	0,014	0,304**	-0,168	0,215*	0,743**	0,007	-0,348**
V2	0,330**	1	0,834**	0,436**	0,353**	-0,069	0,890**	-0,465**	0,420**	0,257*	0,091	-0,458**
V3	0,432**	0,834**	1	0,477**	0,384**	0,050	0,751**	-0,613**	0,619**	0,337**	0,098	-0,443**
V4	0,706**	0,436**	0,477**	1	0,684**	0,062	0,393**	-0,407**	0,081	0,510**	-0,107	-0,541**
V5	0,858**	0,353**	0,384**	0,684**	1	0,003	0,288**	-0,098	0,121	0,619**	0,053	-0,409**
V6	0,014	-0,069	0,050	0,062	0,003	1	-0,108	-0,285**	0,244*	-0,047	-0,037	-0,144
V7	0,304**	0,890**	0,751**	0,393**	0,288**	-0,108	1	-0,450**	0,398**	0,254*	0,112	-0,401**
V8	-0,168	-0,465**	-0,613**	-0,407**	-0,098	-0,285**	-0,450**	1	-0,281**	-0,002	0,062	0,487**
V9	0,215*	0,420**	0,619**	0,081	0,121	0,244*	0,398**	-0,281**	1	0,091	-0,025	-0,045
V10	0,743**	0,257*	0,337**	0,510**	0,619**	-0,047	0,254*	-0,002	0,091	1	0,049	-0,308**
V11	0,007	0,091	0,098	-0,107	0,053	-0,037	0,112	0,062	-0,025	0,049	1	0,000
Quiebra	-0,348**	-0,458**	-0,443**	-0,541**	-0,409**	-0,144	-0,401**	0,487**	-0,045	-0,308**	0,000	1

**Correlación significativa a nivel 0,01 (bilateral)

*Correlación significativa a nivel 0,05 (bilateral)

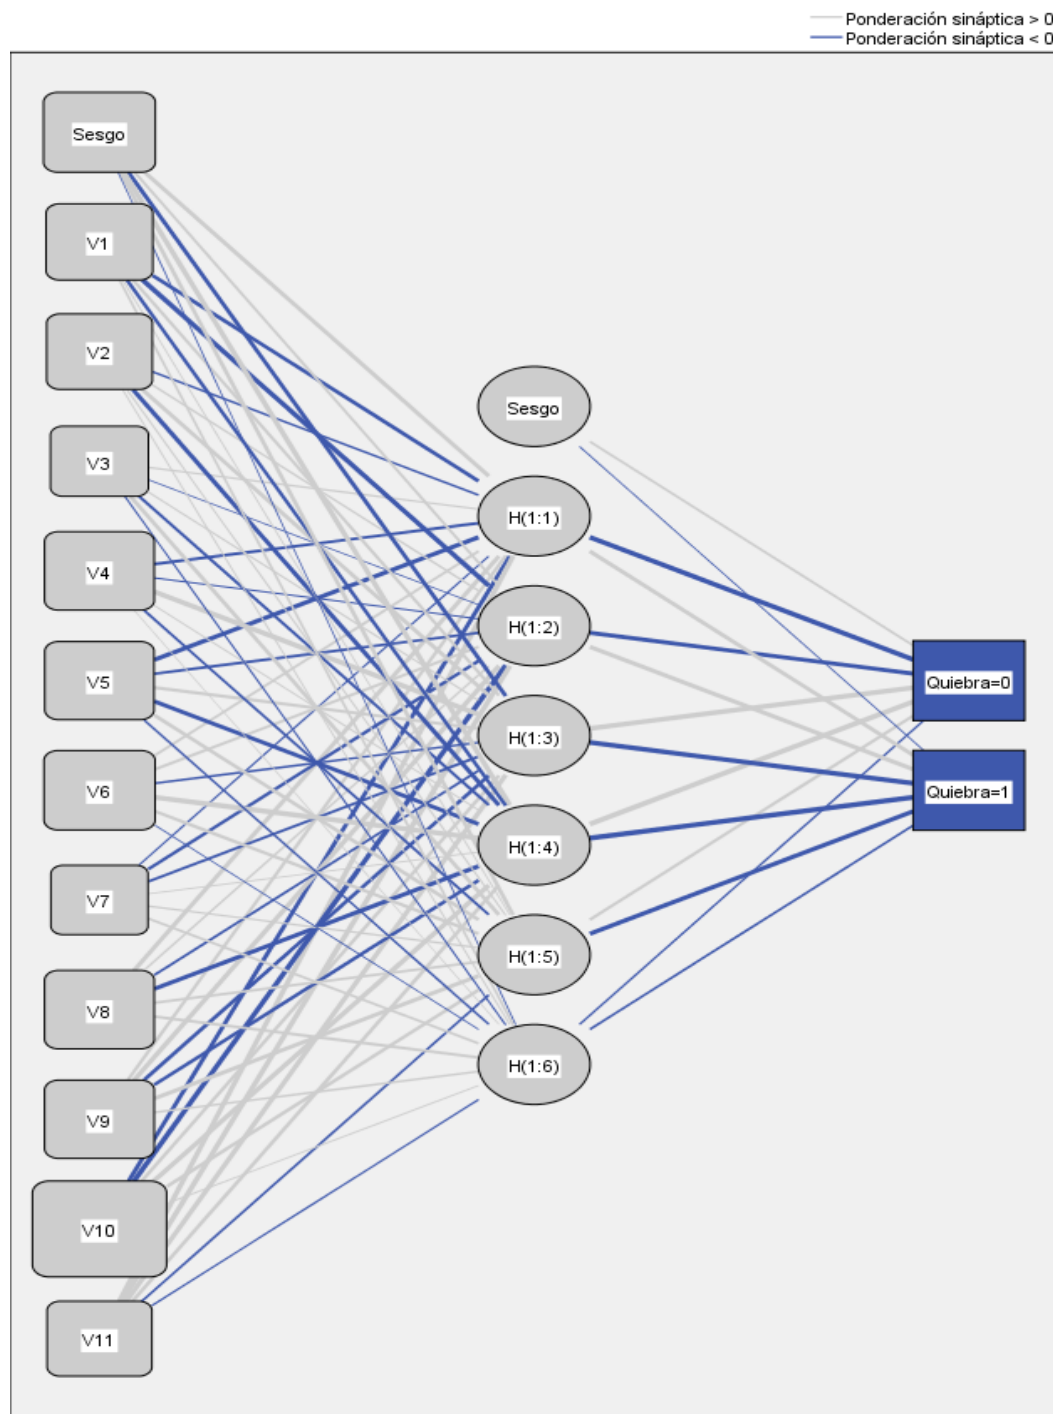
4.2.2.2. *Análisis Confirmatorio*

En la tabla 4.38 y en la figura 4.6 se muestran los resultados del modelo regional construido con la muestra de Asia para t-2. El modelo consta de una capa de entrada con 11 neuronas, una capa oculta con 6 neuronas, y una capa de salida con 2 neuronas. El nivel de clasificación obtenido dentro de la muestra asciende al 98,45% y con la muestra de testeo al 92,18%. La curva COR ha obtenido un valor del 0,993 y las variables de mayor impacto han sido V1, V8 y V6.

TABLA 4.38. MODELO ASIA, t-2

Ajuste del modelo	Valor
Número de neuronas en capa de entrada	11
Número de capas ocultas	1
Número de neuronas en capa oculta	6
Función de activación capa oculta	Tangente hiperbólica
Función de activación capa de salida	Softmax
Curva COR	0,993
Matriz de clasificación	%
Dentro de la muestra	98,45
Quebradas	100,00
No quebradas	97,06
Muestra de testeo	92,18
Quebradas	90,21
No quebradas	93,38
Variables	Importancia Normalizada
V1	58,70%
V2	36,22%
V3	19,07%
V4	47,36%
V5	44,06%
V6	48,33%
V7	17,10%
V8	54,23%
V9	44,86%
V10	10,52%
V11	34,30%

FIGURA 4.6. ARQUITECTURA DE LA RED. MODELO ASIA, t-2



Función de activación de capa oculta: Tangente hiperbólica

Función de activación de capa de resultado: Softmax

4.2.3. RESULTADOS MODELO EUROPA

4.2.3.1. Análisis Exploratorio

El presente apartado incluye el análisis descriptivo, de normalidad, test no paramétricos y de correlación de las variables correspondientes a la muestra de empresas de la región de Europa en t-2.

Los resultados que aparecen en la tabla 4.39 indican que las variables V8 y V9 presentan valores medios inferiores en el grupo de empresas no quebradas. Además, que las variables V1, V4, V5 y V10 muestran signos negativos en sus valores medios para el colectivo de empresas quebradas, y que la desviación típica presenta valores con poca dispersión.

TABLA 4.39. ESTADÍSTICOS DESCRIPTIVOS. MODELO EUROPA, t-2

	Media		Mediana		Desviación Típica		Mínimo		Máximo	
	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas
V1	0,036	-0,122	0,043	-0,095	0,140	0,344	-0,548	-1,092	0,276	0,334
V2	1,953	1,556	1,474	1,067	1,902	0,944	0,384	0,002	4,915	4,903
V3	0,177	0,141	0,156	0,033	0,237	0,257	-0,347	-1,044	0,614	0,744
V4	0,069	-0,313	0,112	-0,008	0,691	1,490	-1,474	-1,985	0,712	0,332
V5	0,079	-0,091	0,065	-0,075	0,100	0,294	-0,246	-0,983	0,371	0,154
V6	1,140	0,987	1,038	0,992	0,577	0,634	0,083	0,035	3,600	3,226
V7	1,358	1,044	0,963	0,656	1,231	0,835	0,062	0,036	3,787	2,073
V8	0,187	0,283	0,172	0,349	0,169	0,193	0,000	0,000	0,608	0,985
V9	0,506	0,587	0,494	0,542	0,215	0,216	0,064	0,062	0,893	0,930
V10	0,101	-0,294	0,097	-0,124	0,201	0,740	-1,720	-8,054	0,576	8,086

Los resultados sobre normalidad indican que, con la excepción de V6, todas las variables en t-2 tienen un nivel de significación inferior al 5%. Esto implica que solo se acepta la hipótesis nula de normalidad en la variable V6 (tabla 4.40).

TABLA 4.40. ANÁLISIS DE NORMALIDAD. MODELO EUROPA, t-2

	NO QUEBRADAS		QUEBRADAS	
	K-S	Sig.	K-S	Sig.
V1	0,035	0,031	0,309	0,008
V2	0,247	0,000	0,235	0,000
V3	0,032	0,027	0,072	0,013
V4	0,157	0,000	0,262	0,002
V5	0,154	0,000	0,157	0,000
V6	0,024	0,073	0,231	0,034
V7	0,168	0,000	0,248	0,000
V8	0,146	0,000	0,156	0,000
V9	0,132	0,000	0,173	0,000
V10	0,248	0,003	0,343	0,000
V11	0,360	0,000	0,558	0,000

NOTA: K-S: test de Kolmogorov-Smirnov

Los tests aplicados a la muestra t-2 indican que tan sólo V6 registra un nivel de significación superior al 5% ($p > 0,05$) para el test de Mann-Whitney, con lo que, sólo en este caso, se acepta la hipótesis nula de igualdad de distribuciones (tabla 4.49).

TABLA 4.41. TESTS NO PARAMÉTRICOS. MODELO EUROPA, t-2

	Test de Mann-Whitney		Test de Kolmogorov-Smirnov	
	M-W	Sig.	K-S	Sig.
V1	2,442	0,035	2,234	0,026
V2	1,747	0,000	1,483	0,000
V3	1,765	0,007	0,753	0,032
V4	5,132	0,000	2,741	0,000
V5	-0,642	0,046	0,523	0,041
V6	4,247	0,112	0,318	0,059
V7	2,948	0,000	1,165	0,000
V8	0,751	0,047	0,645	0,026
V9	0,627	0,023	2,851	0,015
V10	0,676	0,000	2,048	0,000
V11	2,437	0,000	1,675	0,000

NOTA: K-S: test de Kolmogorov-Smirnov; M-W: test de Mann-Whitney

En la tabla 4.42 se muestra el análisis de correlación bilateral conforme al coeficiente de Pearson. En este caso se detecta la existencia de una elevada correlación entre los pares de variables V1 y V5 (0,953); V2 y V7 (0,908); V1 y V10 (0,852); y V1 y V4 (0,846).

TABLA 4.42. ANÁLISIS DE CORRELACIÓN BILATERAL. MODELO EUROPA, t-2

	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11	Quiebra
V1	1	0,127	0,247**	0,846**	0,953**	0,182*	0,094	-0,076	0,083	0,852**	-0,216**	-0,285**
V2	0,127	1	0,727**	0,112	0,115	-0,134	0,908**	-0,347**	0,413**	0,121	0,010	-0,128
V3	0,247**	0,727**	1	0,187*	0,210**	-0,179*	0,687**	-0,445**	0,619**	0,211**	-0,040	-0,050
V4	0,846**	0,112	0,187*	1	0,762**	0,130	0,062	-0,076	0,037	0,602**	-0,198*	-0,164*
V5	0,953**	0,115	0,210**	0,762**	1	0,235**	0,075	-0,079	0,069	0,785**	-0,208**	-0,368**
V6	0,182*	-0,134	-0,179*	0,130	0,235**	1	-0,193*	0,061	0,244**	0,278**	-0,212**	-0,126
V7	0,094	0,908**	0,687**	0,062	0,075	-0,193*	1	-0,424**	0,351**	0,098	0,156*	-0,149
V8	-0,076	-0,347**	-0,445**	-0,076	-0,079	0,061	-0,424**	1	-0,157*	-0,016	-0,207**	0,271**
V9	0,083	0,413**	0,619**	0,037	0,069	0,244**	0,351**	-0,157*	1	0,146	-0,069	0,205**
V10	0,852**	0,121	0,211**	0,602**	0,785**	0,278**	0,098	-0,016	0,146	1	-0,173*	-0,322**
V11	-0,216**	0,010	-0,040	-0,198*	-0,208**	-0,212**	0,156*	-0,207**	-0,069	-0,173*	1	-0,002
Quiebra	-0,285**	-0,128	-0,050	-0,164*	-0,368**	-0,126	-0,149	0,271**	0,205**	-0,322**	-0,002	1

**Correlación significativa a nivel 0,01 (bilateral)

*Correlación significativa a nivel 0,05 (bilateral)

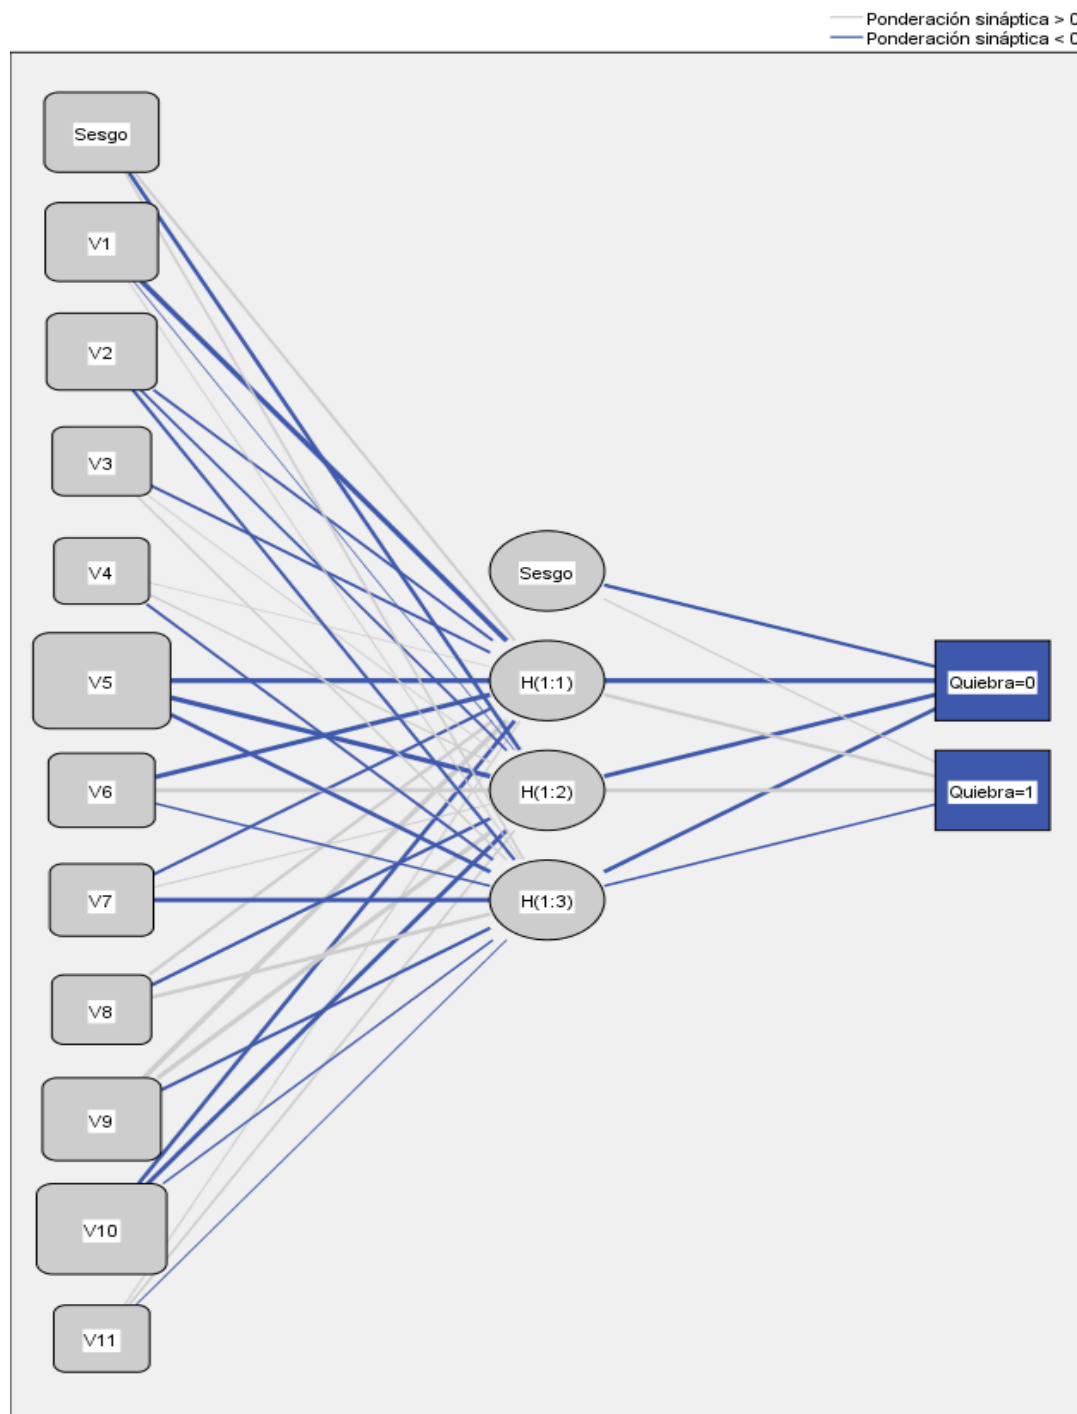
4.2.3.2. *Análisis Confirmatorio*

En la tabla 4.43 y en la figura 4.7 se muestran los resultados del modelo construido con la muestra de la región Europa en t-2. El modelo consta de una capa de entrada (con 11 neuronas), una capa oculta (con 3 neuronas), y una capa de salida (con 2 neuronas). El nivel de clasificación obtenido dentro de la muestra asciende al 83,61%, y en la muestra de testeo al 84,15%. La curva COR ha obtenido un valor del 0,889 y las variables de mayor impacto en el modelo han sido V5, V8 y V4.

TABLA 4.43. MODELO EUROPA, t-2

Ajuste del modelo	Valor
Número de neuronas en capa de entrada	11
Número de capas ocultas	1
Número de neuronas en capa oculta	3
Función de activación capa oculta	Tangente hiperbólica
Función de activación capa de salida	Softmax
Curva COR	0,889
Matriz de clasificación	%
Dentro de la muestra	83,61
Quebradas	79,84
No quebradas	88,66
Muestra de testeo	84,15
Quebradas	82,97
No quebradas	85,57
Variables	Importancia Normalizada
V1	45,91%
V2	49,32%
V3	55,48%
V4	57,62%
V5	100,00%
V6	31,91%
V7	26,63%
V8	67,30%
V9	58,86%
V10	43,68%
V11	8,97%

FIGURA 4.7. ARQUITECTURA DE LA RED. MODELO EUROPA, t-2



Función de activación de capa oculta: Tangente hiperbólica

Función de activación de capa de resultado: Softmax

4.2.4. RESULTADOS MODELO AMÉRICA

4.2.4.1. Análisis Exploratorio

Para la muestra correspondiente a la región América en t-2, los principales estadísticos de las variables aparecen en la tabla 4.44. A tal efecto se comprueba que todas las variables presentan valores medios con signo positivo. Además, se aprecia que el 60% de los valores medios en las empresas no quebradas supera al de las empresas quebradas, mientras que, para la mediana, este porcentaje es del 80%. En concreto, las variables V1, V4, V5 y V10 presentan medias inferiores en el caso de las empresas no quebradas frente a las quebradas. Por su parte, la desviación típica presenta valores con poca dispersión, salvo para V4 y V10.

Tabla 4.44. ESTADÍSTICOS DESCRIPTIVOS. MODELO AMÉRICA, t-2

	Media		Mediana		Desviación Típica		Mínimo		Máximo	
	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas	No quebradas	Quebradas
V1	0,039	0,072	0,039	-0,107	-0,146	0,352	-0,305	-2,434	0,293	0,444
V2	2,268	1,153	2,088	1,106	1,883	2,273	0,456	0,075	5,757	11,346
V3	0,224	0,189	0,217	0,038	0,108	0,252	-0,267	-238,000	0,675	0,907
V4	0,077	0,549	0,190	-0,388	-6,038	45,021	151,000	-375,000	1,566	1,907
V5	0,081	0,097	0,077	-0,027	-0,074	0,243	-0,393	-20,660	0,513	0,174
V6	1,076	0,683	0,906	0,964	1,139	0,84	0,209	0,000	3,025	3,535
V7	1,334	0,836	1,158	0,567	1,229	2,178	0,088	0,044	3,847	10,636
V8	0,266	0,187	0,255	0,405	0,403	0,396	0,000	0,000	0,829	2,367
V9	0,431	0,218	0,428	0,386	0,418	0,23	0,032	0,017	0,832	1,054
V10	0,155	0,400	0,064	0,037	-2,915	28,904	-0,279	-42,590	3,051	13,346

Excentuando la variable V10, todas las variables presentan un nivel de significación inferior al 5% en el test de Kolmogorov-Smirnov, lo que implica rechazar la hipótesis nula de normalidad (tabla 4.45).

Tabla 4.45. ANÁLISIS DE NORMALIDAD. MODELO AMÉRICA, t-2

	NO QUEBRADAS		QUEBRADAS	
	K-S	Sig.	K-S	Sig.
V1	0,035	0,018	0,074	0,007
V2	0,162	0,034	0,115	0,022
V3	0,006	0,000	0,023	0,000
V4	0,277	0,000	0,197	0,000
V5	0,134	0,000	0,136	0,000
V6	0,297	0,000	0,243	0,000
V7	0,379	0,000	0,187	0,000
V8	0,126	0,000	0,088	0,000
V9	0,103	0,006	0,059	0,000
V10	0,027	0,053	0,023	0,014
V11	0,044	0,000	0,147	0,000

NOTA: K-S: test de Kolmogorov-Smirnov

Las variables V5 (únicamente para el test de Mann-Whitney) y V10 (para los tests de Mann-Whitney y Kolmogorov-Smirnov) muestran un nivel de significación superior al 5% ($p > 0,05$), por lo que se aceptaría sólo en estos casos la hipótesis nula de igualdad de distribuciones (tabla 4.46).

Tabla 4.46. TESTS NO PARAMÉTRICOS. MODELO AMÉRICA, t-2

	Test de Mann-Whitney		Test de Kolmogorov-Smirnov	
	M-W	Sig.	K-S	Sig.
V1	1,675	0,000	1,522	0,000
V2	2,834	0,035	0,837	0,011
V3	0,764	0,017	2,665	0,022
V4	1,138	0,000	0,147	0,000
V5	0,652	0,053	0,747	0,041
V6	3,857	0,000	0,865	0,000
V7	0,859	0,000	0,072	0,000
V8	1,914	0,000	0,695	0,000
V9	0,742	0,000	0,805	0,000
V10	1,763	0,758	0,137	0,726
V11	2,956	0,007	2,985	0,000

NOTA: K-S: test de Kolmogorov-Smirnov; M-W: test de Mann-Whitney

Para finalizar el análisis exploratorio, y conforme a los resultados que aparecen en la tabla 4.47, se detecta la existencia de una elevada correlación entre las variables V2 y V7 (0,906) y entre V4 y V7 (-0,838).

TABLA 4.47. ANÁLISIS DE CORRELACIÓN BILATERAL. MODELO AMÉRICA, t-2

	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11	Quiebra
V1	1	-0,208**	-0,138	0,350**	0,760**	0,125	-0,356**	-0,325**	-0,222**	0,032	-0,140	-0,382**
V2	-0,208**	1	0,719**	-0,669**	-0,122	-0,128	0,906**	-0,232**	0,443**	0,067	0,200*	-0,105
V3	-0,138	0,719**	1	-0,260**	-0,140	0,059	0,525**	-0,338**	0,724**	0,288**	0,223**	-0,214**
V4	0,350**	-0,669**	-0,260**	1	0,264**	0,118	-0,838**	0,059	-0,206**	0,001	-0,133	-0,094
V5	0,760**	-0,122	-0,140	0,264**	1	0,145	-0,241**	-0,375**	-0,225**	0,016	-0,238**	-0,392**
V6	0,125	-0,128	0,059	0,118	0,145	1	-0,194*	-0,146	0,377**	0,062	-0,118	0,019
V7	-0,356**	0,906**	0,525**	-0,838**	-0,241**	-0,194*	1	-0,211**	0,297**	0,049	0,216**	-0,028
V8	-0,325**	-0,232**	-0,338**	0,059	-0,375**	-0,146	-0,211**	1	-0,246**	-0,112	0,033	0,214**
V9	-0,222**	0,443**	0,724**	-0,206**	-0,225**	0,377**	0,297**	-0,246**	1	0,070	0,213**	0,010
V10	0,032	0,067	0,288**	0,001	0,016	0,062	0,049	-0,112	0,070	1	0,010	-0,074
V11	-0,140	0,200*	0,223**	-0,133	-0,238**	-0,118	0,216**	0,033	0,213**	0,010	1	0,000
Quiebra	-0,382**	-0,105	-0,214**	-0,094	-0,392**	0,019	-0,028	0,214**	0,010	-0,074	0,000	1

**Correlación significativa a nivel 0,01 (bilateral)

*Correlación significativa a nivel 0,05 (bilateral)

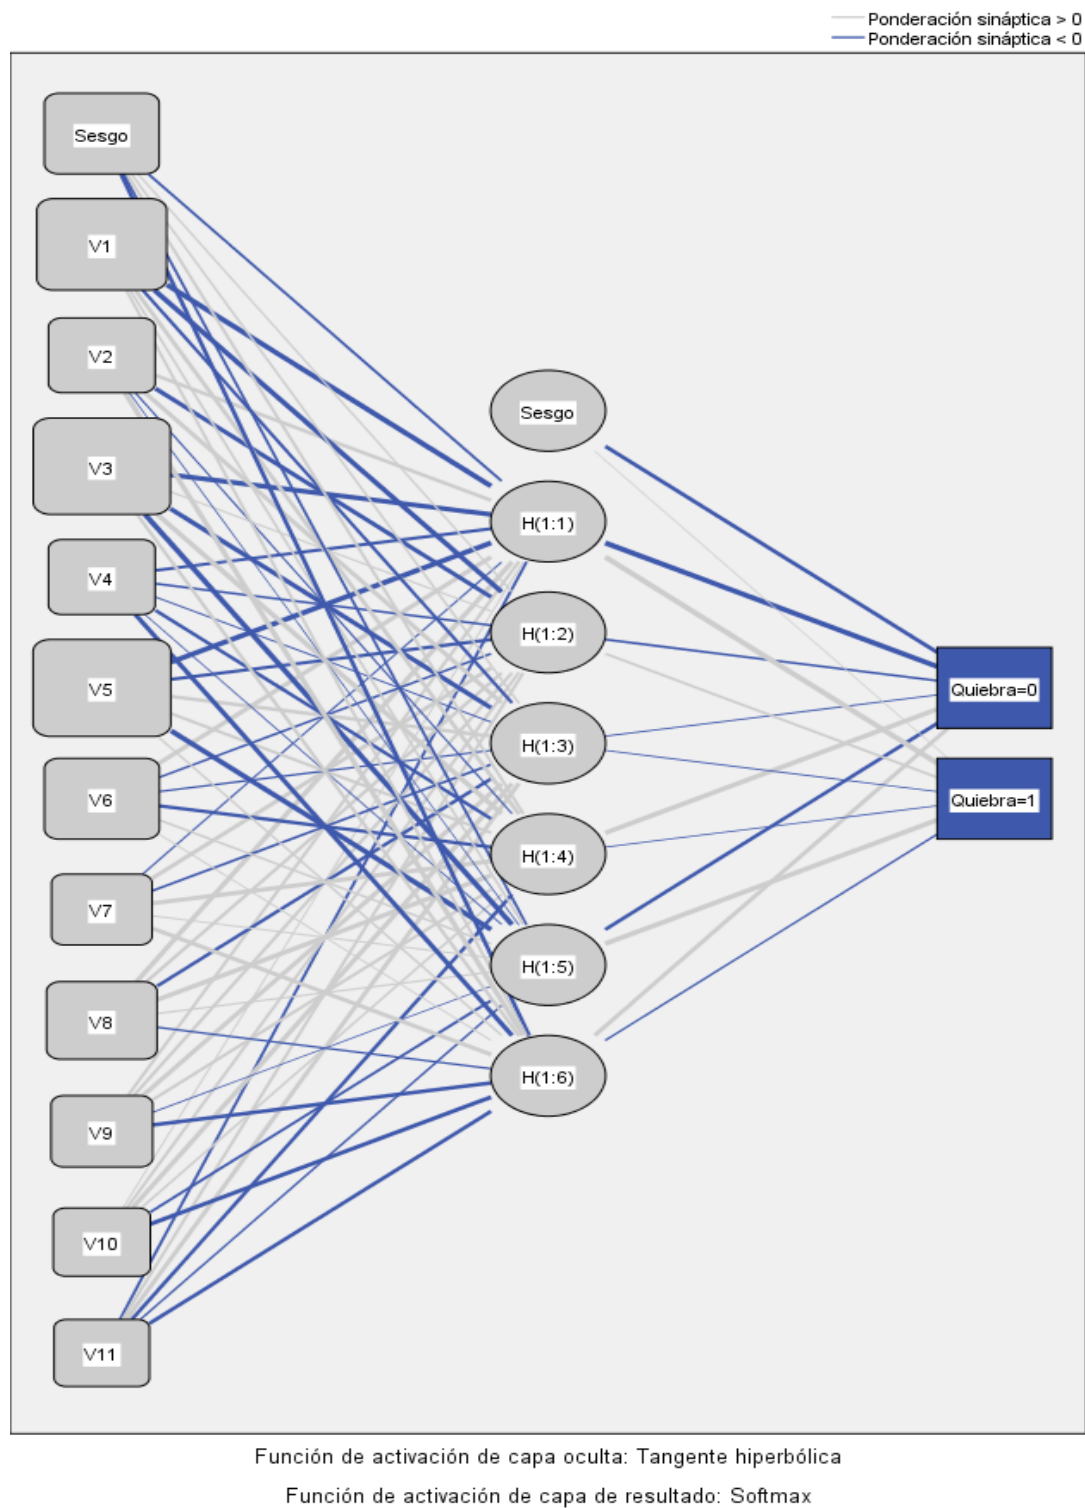
4.2.4.2. Análisis Confirmatorio

En la tabla 4.48 y en la figura 4.8 se muestran los resultados del modelo regional desarrollado para la muestra de América en t-2. El modelo consta de una capa de entrada con 11 neuronas, una capa oculta con 6 neuronas, y una capa de salida con 2 neuronas. El nivel de clasificación obtenido dentro de la muestra asciende al 81,15% y fuera de la muestra al 87,26%. La curva COR ha obtenido un valor del 0,882, lo que indica una alta fiabilidad del poder de clasificación del modelo. Por último, el análisis de sensibilidad realizado nos ha permitido determinar que las variables de mayor impacto han sido V5, V3 y V1 (con una importancia normalizada del 100,00%, 98,36% y 62,79%, respectivamente).

TABLA 4.48. MODELO AMÉRICA, t-2

Ajuste del modelo	Valor
Número de neuronas en capa de entrada	11
Número de capas ocultas	1
Número de neuronas en capa oculta	6
Función de activación capa oculta	Tangente hiperbólica
Función de activación capa de salida	Softmax
Curva COR	0,882
Matriz de clasificación	%
Dentro de la muestra	81,15
Quebradas	71,24
No quebradas	89,87
Muestra de testeo	87,26
Quebradas	84,72
No quebradas	90,91
Variables	Importancia Normalizada
V1	62,79%
V2	31,82%
V3	98,36%
V4	32,28%
V5	100,00%
V6	50,19%
V7	19,10%
V8	60,37%
V9	21,24%
V10	11,43%
V11	7,42%

FIGURA 4.8. ARQUITECTURA DE LA RED. MODELO AMÉRICA, t-2



4.2.5. COMPARACIÓN DEL MODELO GLOBAL CON LOS MODELOS REGIONALES EN $t-2$

En este apartado corresponde dar respuesta a lo postulado por la hipótesis H_1 en referencia a $t-2$. Esta hipótesis plantea si un modelo global era igual o distinto a los modelos regionales estimados a partir de muestras específicas de cada región. A tal efecto, y conforme a los resultados que aparecen en la tabla 4.49, es posible concluir que los modelos estimados son distintos, pues presentan variables predictoras diferentes. Por consiguiente, también se acepta para $t-2$ la hipótesis H_1 planteada.

TABLA 4.49. MODELOS GLOBAL Y REGIONALES, t-2

Ajuste del Modelo	Global	Asia	Europa	América
Número de neuronas en capa de entrada	11	11	11	11
Número de capas ocultas	4	6	3	6
Número de neuronas en capa oculta	2	2	2	2
Curva COR	0,898	0,993	0,889	0,882
Matriz de Clasificación (%)				
Fuera de la Muestra				
No quebradas	89,12	93,38	85,57	90,91
Quebradas	82,65	90,21	82,97	84,72
Total	85,62	92,18	84,15	87,26
Predictores	V1		V3	V1
	V2		V4	V3
	V4	V1	V5	V5
	V5	V8	V8	V6
	V8		V9	V8
	V9			

NOTAS: Predictores con un impacto normalizado $\geq 50\%$

4.2.6. MODELO GLOBAL CON VARIABLE REGIONAL

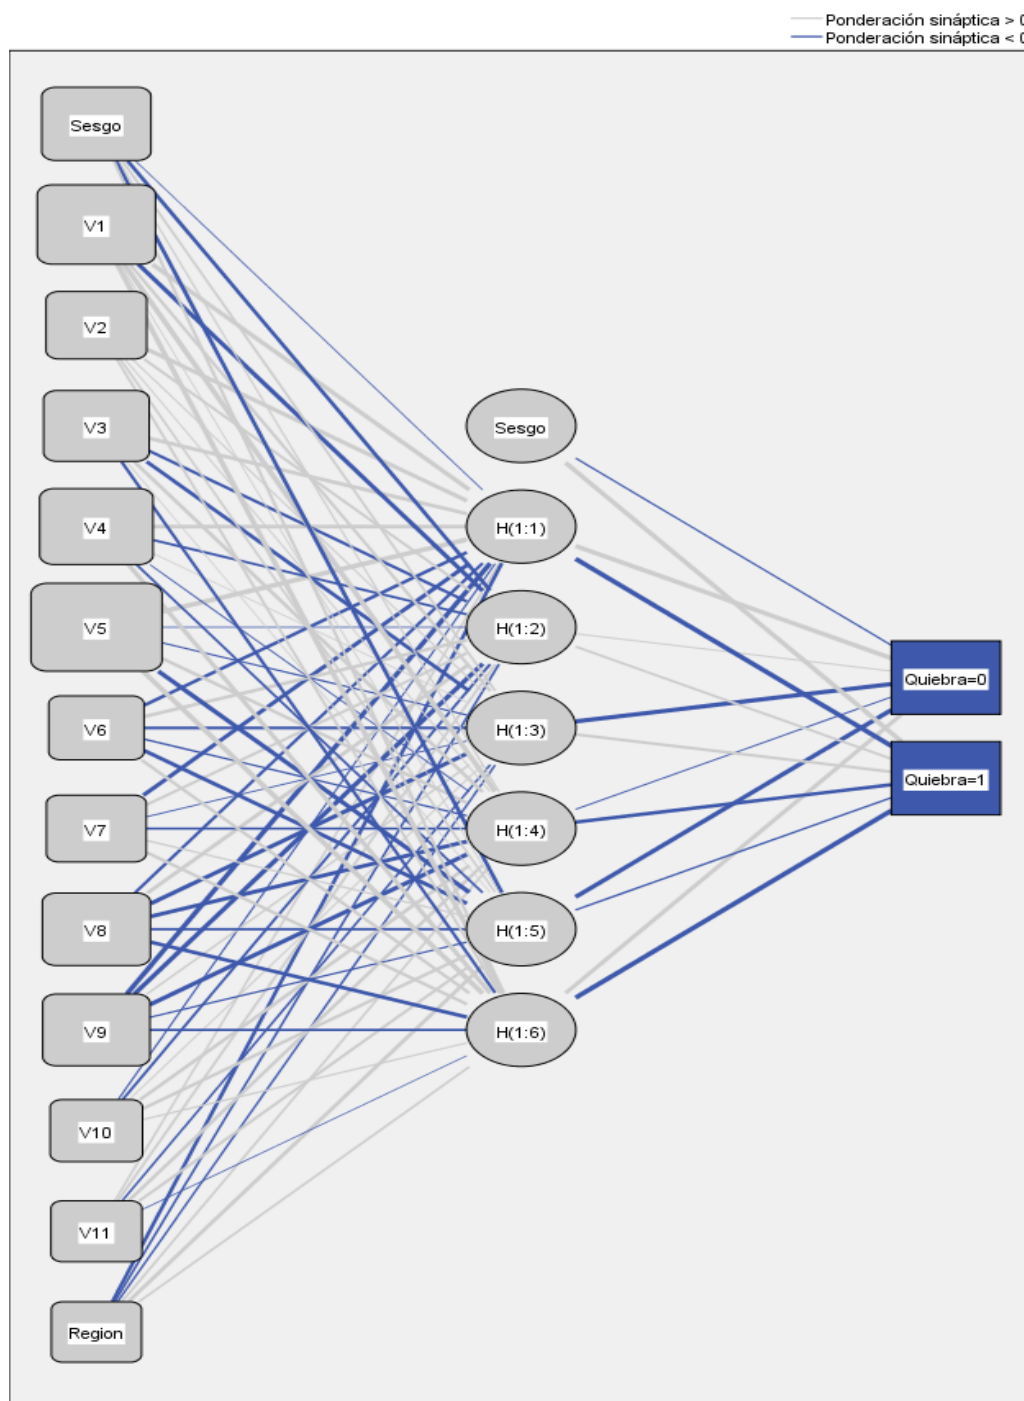
En este apartado se aborda el contraste de la hipótesis H_2 sobre si la inclusión de la variable regional (representativa de las regiones consideradas) en el modelo global, mejora el ajuste y la precisión de dicho modelo. Para dar respuesta a esta cuestión, se procederá, en primer lugar, a la estimación de un modelo global para t-2 introduciendo una variable representativa de las regiones incluidas en la muestra. En segundo lugar, se compararán los resultados así obtenidos con los correspondientes al modelo global estimado sin la participación de esta variable regional.

En la tabla 4.50 y en la figura 4.9 se muestran los resultados del modelo obtenido para la muestra global con variable regional en t-2. El modelo está constituido por una capa de entrada con 12 neuronas, una capa oculta con 6 neuronas, y una capa de salida con 2 neuronas. El nivel de clasificación obtenido dentro de la muestra asciende al 79,55%, y fuera de la muestra al 83,85%. La curva COR ha obtenido un valor muy aceptable (0,880), y las variables de mayor impacto han resultado ser V5, V2 y Región.

TABLA 4.50. MODELO GLOBAL CON VARIABLE REGIONAL, t-2

Ajuste del modelo		Valor
Número de neuronas en capa de entrada		12
Número de capas ocultas		1
Número de neuronas en capa oculta		6
Función de activación capa oculta		Tangente hiperbólica
Función de activación capa de salida		Softmax
Curva COR		0,880
Matriz de clasificación		%
Dentro de la muestra		79,55
Quebradas		72,14
No quebradas		86,27
Muestra de testeo		86,85
Quebradas		82,28
No quebradas		89,36
Variables		Importancia Normalizada
V1		30,73%
V2		70,05%
V3		41,54%
V4		39,23%
V5		100,00%
V6		18,00%
V7		28,34%
V8		47,15%
V9		44,95%
V10		11,29%
V11		8,11%
REGIÓN		56,28%

**FIGURA 4.9. ARQUITECTURA DE LA RED. MODELO GLOBAL SIN
VARIABLE REGIONAL, t-2**



Función de activación de capa oculta: Tangente hiperbólica

Función de activación de capa de resultado: Softmax

Para llevar a cabo la comparación propuesta se han utilizado los tres criterios de información ya utilizados en el presente capítulo. Como puede comprobarse a partir de los valores que aparecen en la tabla 4.51, el modelo global con la variable Región es superior al modelo global estimado sin dicha variable cualitativa. De esta forma, los resultados obtenidos permiten aceptar, también para $t-2$, la hipótesis H_2 , implicando que la inclusión de esta variable regional aumenta la capacidad de explicación del modelo global.

TABLA 4.51. COMPARACIÓN DE MODELOS GLOBALES, $t-2$.

Ajuste del Modelo	Global SIN VARIABLE REGIÓN	Global CON VARIABLE REGIÓN
Número de neuronas en capa de entrada	11	12
Número de capas ocultas	1	1
Número de neuronas en capa oculta	4	6
Curva COR	0,898	0,880
Matriz de Clasificación (%)		
Fuera de la Muestra		
No quebradas	89,12	89,36
Quebradas	82,65	82,28
Total	85,62	86,85
Criterio de Akaike	291,028	118,933
Criterio de Schwartz	295,532	145,138
Criterio de Hannan-Quinn	282,572	128,101

4.2.7. ANÁLISIS DE ROBUSTEZ

El análisis de robustez para t-2 permitirá conocer si se acepta o se rechaza la hipótesis H_3 (en referencia a la capacidad del modelo global con variable regional para predecir correctamente con las muestras de las diferentes regiones).

De los resultados que aparecen en las tablas 4.52 y 4.53 se deduce que dicho modelo global es capaz de predecir con éxito sobre las diferentes muestras regionales. Estos resultados permiten aceptar, también para t-2, la hipótesis H_3 .

TABLA 4.52. RESULTADOS DE LOS MODELOS PARA t-2.

Ajuste del Modelo	Global	Asia	Europa	América
Número de neuronas en capa de entrada	12	11	11	11
Número de capas ocultas	1	1	1	1
Número de neuronas en capa oculta	6	6	3	6
Curva COR	0,880	0,993	0,889	0,882
Matriz de Clasificación (%)				
Fuera de la Muestra				
No quebradas	89,36	93,38	85,57	90,91
Quebradas	82,28	90,21	82,97	84,72
Total	86,85	92,18	84,15	87,26
Criterio de Akaike	116,754	34,235	42,275	53,221
Criterio de Schwartz	141,560	45,055	65,723	71,693
Criterio de Hannan-Quinn	124,352	38,147	53,156	62,394

TABLA 4.53. ROBUSTEZ DEL MODELO GLOBAL CON VARIABLE REGIONAL, t-2.

Ajuste del Modelo	Asia	Europa	América
Número de neuronas en capa de entrada	3	3	3
Número de capas ocultas	1	1	1
Número de neuronas en capa oculta	4	2	7
Curva COR	0,965	0,927	0,909
Matriz de Clasificación (%)			
Fuera de la Muestra			
No quebradas	91,27	92,54	92,19
Quebradas	94,86	96,82	89,52
Total	92,72	94,15	90,48
Criterio de Akaike	15,257	41,477	42,272
Criterio de Schwartz	29,723	41,128	51,172
Criterio de Hannan-Quinn	23,241	47,728	57,570

4.3.1 ANÁLISIS COMPARATIVO DE RESULTADOS

En la tabla 4.54 aparece los resultados de la comparación de las variables significativas entre modelos globales y regionales correspondientes a t-1 y t-2. Conforme a dichos resultados se comprueba que los modelos globales y regionales son distintos. Es decir, aunque pueden contener variables comunes en algunos casos, no son modelos iguales.

TABLA 4.54. COMPARACIÓN ENTRE MODELOS GLOBALES Y REGIONALES, t-1 y t-2

Ajuste del Modelo	Global	Asia	Europa	América
Variables de los modelos en t-1	V3	V1	V1	V3
	V5	V3	V2	V5
	V8	V4	V3	V6
	V9	V8	V5	V10
	V10	V10	V7	
			V8	
			V9	
Variables de los modelos en t-2	V1	V1	V3	V1
	V2	V8	V4	V3
	V4		V5	V5
	V5		V8	V6
	V8		V9	V8
	V9			

Respecto a la inclusión de variable regional en los modelos globales, la tabla 4.55 ofrece también una comparación de los resultados alcanzados tanto para t-1 como para t-2. Como se puede comprobar, la inclusión de la variable Región mejora los modelos globales estimados a tenor de la comparación efectuada a través de los criterios de Akaike, Schwartz y Hannan-Quinn.

TABLA 4.55. COMPARACIÓN ENTRE LOS MODELOS GLOBALES, t-1 y t-2.

Criterios de Selección de Modelos	t-1		t-2	
	Global SIN VARIABLE REGIÓN	Global CON VARIABLE REGIÓN	Global SIN VARIABLE REGIÓN	Global CON VARIABLE REGIÓN
Criterio de Akaike (AIC)	213,537	101,385	291,028	118,933
Criterio de Schwartz (BIC)	224,054	118,542	295,532	145,138
Criterio de Hannan-Quinn (HQC)	218,396	104,258	282,572	128,101

Por último, la tabla 4.56 informa de la capacidad de los modelos globales para predecir correctamente con las muestras de las diferentes regiones. Se ha podido comprobar que los modelos globales en t-1 y t-2 son más precisos que los modelos regionales, incluso en las propias muestras regionales.

TABLA 4.56. RESULTADOS DE LOS MODELOS REGIONALES Y MODELOS GLOBALES EN LAS MUESTRAS REGIONALES

	1 AÑO ANTES QUIEBRA (t-1)			2 AÑOS ANTES QUIEBRA (t-2)		
	<i>AIC</i>	<i>BIC</i>	<i>HQC</i>	<i>AIC</i>	<i>BIC</i>	<i>HQC</i>
ASIA						
<i>Modelo</i>	14,637	26,812	18,259	34,235	45,055	38,147
<i>Validación Cruzada</i>	11,148	22,289	15,865	15,257	29,723	23,241
EUROPA						
<i>Modelo</i>	34,765	54,924	43,862	42,275	65,723	53,156
<i>Validación Cruzada</i>	32,562	47,432	42,985	41,477	46,128	47,728
AMÉRICA						
<i>Modelo</i>	37,832	51,185	40,932	53,221	71,693	62,394
<i>Validación Cruzada</i>	33,238	48,157	37,630	42,272	51,172	57,570

AIC: Akaike, BIC: Bayesian, HQC: Hannan-Quinn

BIBLIOGRAFÍA CAPÍTULO 4

Alaminos, D., del Castillo, A. y Fernández, M.Á. (2016) A global model for bankruptcy prediction. PLoS ONE 11(11): e0166693.

Allen, D.M. (1974). The relationship between variable selection and data augmentation and a method for prediction. *Technometrics*, 16, 125–127.

Bradley, A.P. (1997). The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30 (7), 1145-1159

Fernández, M.A.; Gil, A.M. y López, P. (2009). Estructura y Equilibrio financiero de las PYMES Españolas ante las Nuevas Exigencias de Información Financiera. Fundación de las Cajas de Ahorros. Madrid.

López, M. y López, J. (1996). Estadística para actuarios. Editorial Mapfre, Madrid.

Stone, M. (1974). Cross-validation choice and assessment of statistical predictions. *Journal of the Royal Statistical Society: Series B*, 36, 111–147.

Visauta, B. (2003). Análisis Estadístico con SPSS para Windows, Vol. II. E. McGraw-Hill.

Zhang, Y. y Yang, Y. (2015). Cross-validation for selecting a model selection procedure. *Journal of Econometrics*, 187, 95–112.

DISCUSIÓN DE RESULTADOS

En esta sección se analizarán de manera detallada los resultados alcanzados para los distintos modelos regionales y globales estimados para predecir la quiebra con 1 y 2 años de antelación. Así mismo, se compararán estos resultados con los modelos obtenidos en investigaciones previas, principalmente con los modelos globales y regionales del estudio de Alaminos, del Castillo y Fernández (2016).

Los modelos contruidos con datos correspondientes a $t-1$, tanto regionales como globales (sin y con variable regional), han alcanzado buenos resultados en términos del porcentaje de clasificación en la muestra de testeo. Estos porcentajes oscilaron entre el 95,26% obtenido por el modelo de Europa y el 89,35% registrado por el modelo de América.

Hay que apuntar que todos los modelos regionales han incorporado variables explicativas que la literatura previa identificó como particulares de esa región. Así, en Asia destacó la variable V4 (Beneficio No Distribuido/Activos Totales), en Europa V8 (Deuda Total/Total Activos), y en América V3 (Capital de Explotación/Activos Totales).

Por su parte, los modelos globales, sin variable regional y con ella, consiguieron unos porcentajes de clasificación del 88,79 y del 94,33% en la muestra de testeo, respectivamente.

Al realizar los tests no paramétricos en el análisis exploratorio se comprobó que un gran número de las 11 variables consideradas se mostraban como variables estadísticamente relevantes en la predicción de la quiebra en las distintas regiones consideradas, siendo pocas las que no han mostrado ningún signo de relevancia. Así, en la muestra de Asia sólo con V5 y V8 se aceptó la hipótesis nula de igualdad de parámetros en las distribuciones de empresas quebradas y no

quebradas, respectivamente. Para Europa, V3 y V8. Para la muestra de América, solo V10. Finalmente, en la muestra global, solo las variables V5 y V8 aceptaron la hipótesis nula en los tests no paramétricos.

Los resultados obtenidos en el análisis confirmatorio sustentaron los obtenidos en el análisis exploratorio, resultando explicativas aquellas variables que previamente se habían mostrado como relevantes estadísticamente, con la única excepción de V5 en la muestra de Asia, que presentaron la suficiente relevancia estadística en los tests no paramétricos y, sin embargo, no resultaron ser significativas en los modelos regionales.

Así, las variables con un mayor impacto (igual o superior al 50%) para predecir la quiebra en Asia con información correspondiente a t-1 fueron V1, V3, V4, V8 y V10. Para la muestra de Europa resultaron ser las variables V1, V2, V3, V5, V7, V8 y V9. Para América, V3, V5, V6 y V10. Finalmente, en el modelo global sin variable regional, V3, V5, V8 y V9, y en el modelo global con variable regional V3, V5, V9 y la dummy Región.

Si analizamos los resultados de las curvas COR obtenidos en los distintos modelos estimados se comprueba que la bondad de ajuste, o lo que es lo mismo, la fiabilidad de los modelos, es bastante alta. El rango de resultados va desde un COR de 0,985 para el modelo de Asia hasta un 0,902 para el modelo global sin variable regional.

Como puede comprobarse, el Capital de Explotación/Activos Totales, con la nomenclatura V3, resultó explicativa en todos los modelos estimados. Evidencia la importancia que tiene para cualquier empresa el activo circulante apoyado por recursos permanentes, ya que es una medida que muestra la capacidad que tiene una empresa

para continuar con el normal desarrollo de sus actividades en el corto plazo.

Otras tres variables han aparecido como comunes en casi todos los modelos: V5, V9 y V10. En el caso de V9 (EBIT/Activos Totales) y V10 (Ingresos Netos/Patrimonio Neto), aparecen como variables con una alta correlación en prácticamente todas las regiones. Son variables explicativas de la rentabilidad, lo que viene a evidenciar la importancia de este parámetro en relación con la quiebra. En este sentido, resulta oportuno pensar que una de las causas más inmediatas de la quiebra son los problemas de rentabilidad, que terminan precipitando la quiebra empresarial, debido a la dificultad de generar beneficios con su actividad habitual. Por su parte, la variable V9 (Activos Corrientes/Activos Totales) incidiría en el aspecto de la liquidez, al ponerse de manifiesto que un margen pequeño de activos corrientes frente a los activos totales termina teniendo repercusión sobre la quiebra empresarial.

Parece razonable, pues, que estas tres variables relacionadas con la capacidad de la empresa de atender sus obligaciones sean las que hayan sido significativas prácticamente en todos los modelos y regiones, con datos de 1 año antes de la quiebra (t-1).

En este mismo sentido, entendemos que las variables representativas del endeudamiento total, como V8 (Total Deuda/Total Activo), hayan aparecido de manera casi exclusiva como predictores significativos de la quiebra en dos regiones, Asia y Europa, además del modelo global. No obstante, se sigue repitiendo la línea de significatividad de las variables de rentabilidad, como V1 (Ingresos Netos/Activos Totales) y V4 (Beneficio No Distribuido/Activos Totales)

Si comparamos los resultados obtenidos en la literatura previa en los denominados modelos regionales, o elaborados a partir de muestras heterogéneas de países, con los estimados en el presente estudio, puede constatarse que estos últimos se sitúan en un rango alto de nivel de precisión, aunque existen trabajos previos que muestran buenos resultados de precisión. Así, encontramos trabajos que presentan excelentes resultados en la muestra de testeo como el de Tsai et al. (2014), con un porcentaje de acierto del 85,66%, y otros que se sitúan con unos resultados inferiores como el de Charalambous et al. (2000) con un 77,9% en el testeo, e incluso el resultado de Chen et al. (2011) con un porcentaje de acierto en la muestra de testeo del 64,5%. Por último, los resultados obtenidos por Alaminos et al (2016) con Logit fueron inferiores a los arrojados en el presente estudio, con un porcentaje de acierto del 84,86% para los datos de testeo.

Con respecto a las variables utilizadas, existe heterogeneidad, sin encontrarse un patrón común entre los trabajos previos y los modelos globales desarrollados en el presente estudio. Hay algunas variables comunes como, por ejemplo, V1, V4 y V5, que han sido utilizadas por Tsai et al. (2014). También encontramos que V2 y V3 fueron empleadas también por Chen et al. (2011), apareciendo únicamente V9 en común con el trabajo de Charalambous et al. (2000).

Con respecto al modelo estimado para la muestra de Asia, sólo el trabajo de Tsai et al. (2014) utilizó el perceptrón multicapa en su estudio, con un porcentaje de clasificación en la muestra de entrenamiento del 83,68% para t-1. En este sentido, nuestro modelo ofrece un mejor resultado, alcanzando el 86,42% en la muestra de entrenamiento y el 91,93% en la muestra de testeo.

Nuestro modelo estimado para la muestra de Europa en t-1 obtuvo un resultado en la muestra de testeo del 95,26%, resultado

superior al obtenido por Korol (2013), sólo un 85,18%. Por debajo de estos resultados se encuentran los trabajos de Altman et al. (2017), Laitinen y Suvas (2013) y duJardin (2018).

Con el trabajo de Korol (2009) encontramos en común las variables V2 y V3. Con el trabajo de Altman et al. (2017) se comparte únicamente la variable V3. Por otro lado, con Laitinen y Suvas (2013) solo se coincide en la variable V2.

En la muestra de América, nuestro resultado se ha situado en el 89,36% de acierto en la clasificación con la muestra de testeo para t-1, solo mejorado por el resultado obtenido por Platt y Platt (2008), pues alcanzó un 94,5%. Entre las variables utilizadas, no compartimos con Platt y Platt (2008) variable alguna, y con Altman (1993) la variable V3.

Por lo que se refiere al modelo global, nuestro modelo (sin variable regional) ha obtenido un porcentaje de clasificación del 88,79% en la muestra de testeo; y con variable regional, de un 89,36%. Este porcentaje no es superado por el obtenido por Altman et al. (2010), que sólo fue de un 80,16% de acierto en la muestra de testeo. Otros trabajos, como el de Pindado (2011), obtuvieron un porcentaje cercano al nuestro, un 87%, pero con la muestra de entrenamiento.

Cabe destacar que el objetivo de obtener unas conclusiones comparables con los trabajos realizados por el resto de autores sobre predicción de quiebra nos ha llevado también a utilizar un número acotado de variables, que se corresponderían con todas las que inicialmente fueron consideradas en los diferentes trabajos de investigación, dentro de la revisión hecha por Bellovary et al. (2007), siendo escogidas las variables que hayan sido utilizadas en un mínimo

de 20 estudios previos. Este hecho hace que muchas de estas variables sean bastante similares y muestren información con escasas diferencias, presentando niveles de correlación relativamente altos entre ellas, si bien no se ha prescindido de ninguna con objeto de obtener unas conclusiones más robustas.

Por otro lado, los modelos de PMC desarrollados en el presente trabajo obtuvieron unos porcentajes de clasificación levemente superiores que los modelos Logit para t-1 del estudio de Alaminos, del Castillo y Fernández (2016). De igual forma, mostraron un mejor rendimiento en la validación cruzada con el uso del modelo global en todas las regiones estudiadas. Además, el conjunto de variables significativas para cada caso arrojó algunas diferencias respecto a los modelos Logit citados. En el caso del modelo de Asia, con Logit las variables significativas fueron V1, V4 y V8, mientras que con PMC se incluyen, además, V3 y V10. Para el modelo de Europa, en el caso de Logit las variables fueron V1, V2, V5, V8 y V9, y con PMC se incluyeron en ese conjunto V3 y V7. Para el modelo de América, en el caso de Logit las variables fueron V3, V5 y V6, y con PMC, V10.

Por su parte, los resultados obtenidos por los modelos estimados con información t-2 obtuvieron peores resultados que los obtenidos para t-1, hecho este habitual en los modelos de predicción de quiebra. En concreto, los resultados oscilaron entre el 92,18% de clasificación registrado en el modelo de Asia y el 84,15% obtenido en el modelo de Europa.

El análisis exploratorio llevado a cabo en t-2 mostró que prácticamente todas las variables consideradas fueron relevantes en la predicción de la quiebra en las diferentes regiones, siendo muy pocas las que no mostraron ningún signo de relevancia. Por ejemplo, en la muestra de Asia para V3, V5 y V8 se aceptaron la hipótesis nula de

igualdad de parámetros en las distribuciones. En Europa, sólo para V6. En la muestra de América, para V5 y V10. Además, en la muestra global solo V7 aceptó la hipótesis nula en los tests no paramétricos.

Los resultados obtenidos en el análisis confirmatorio corroboraron los obtenidos en el análisis exploratorio, resultando explicativas aquellas variables que previamente se habían mostrado como relevantes estadísticamente, con las excepciones de las variables V3 y V8 para Asia, V6 para la muestra de Europa y V10 para América, que presentaron la suficiente relevancia estadística en los tests no paramétricos y, sin embargo, no resultaron ser significativas en los modelos regionales.

Así, las variables explicativas de la quiebra en la región de Asia fueron las variables V1 y V8, para t-2. En el caso de Europa resultaron como variables explicativas V3, V4, V5, V8 y V9. Para el caso de América resultaron ser las variables V1, V3, V5, V6 y V8. Finalmente, en el modelo global sin variable regional, V1, V2, V4, V5, V8 y V9, y en el modelo global con dummy regional, V2, V5 y dicha dummy.

En todos los modelos para t-2, la variable Ingresos Netos/Activos Totales, con la nomenclatura V1, resultó explicativa. Como era de esperar, esta variable señala que, cuanto mayor sea el beneficio neto obtenido por la empresa por unidad monetaria invertida en su activo, menor será su probabilidad de quiebra. Por tanto, tiene signo negativo. Otra variable que aparece en todos los modelos es V8 (Deuda Total/Activos Totales). Esta variable indica que, cuanto mayor sea el endeudamiento generado por la empresa por unidad monetaria invertida en su activo, mayor será su probabilidad de quiebra. Por tanto, tendría signo positivo.

Otras dos variables han aparecido como comunes en casi todos los modelos: V5 y V9. En el caso de V5 (EBIT/Activos Totales) y V9 (Activos Corrientes/Activos Totales), al igual que en $t-1$, aparecen como variables altamente correlacionadas en prácticamente todas las regiones. Son variables representativas tanto de la rentabilidad como de la liquidez a corto plazo, lo que viene a evidenciar la importancia de estos parámetros en relación con la quiebra, con independencia de la región que se trate. Por tanto, la imposibilidad de generar beneficios, así como de atender las obligaciones contraídas con los acreedores, son relevantes respecto al desenlace de la quiebra, tanto al corto plazo ($t-1$) como a un mayor plazo ($t-2$).

En este plazo de $t-2$ sí emerge, como una variable destacada en tres de los modelos, la variable V8 (Total Deuda/Total Activo), que recoge el efecto que el volumen de endeudamiento genera en el balance de una empresa y su relación con la quiebra. Sin embargo, esta variable no resultó tan significativa en $t-1$.

Si comparamos los resultados obtenidos en la literatura previa sobre los denominados modelos descentrados, o elaborados a partir de muestras heterogéneas de regiones, con los estimados en el presente estudio, puede también constatar que los resultados aquí obtenidos se sitúan en un rango alto de nivel de precisión. Para $t-2$, Charalambous et al. (2000) dan un porcentaje de acierto en la muestra de testeo del 68,6%, situándose por debajo de nuestro modelo.

En relación con el modelo estimado para Asia, los resultados de nuestro modelo en $t-2$ muestran un resultado de clasificación con la muestra de testeo del 92,18%, mejor que el modelo de Zhou (2013), que obtiene un 78,68%. Por otra parte, la única variable significativa que aparece en nuestro modelo y que se utiliza también en el trabajo de Zhou (2013) es V1. El modelo de Europa estimado con la muestra

t-2 registró un resultado del 84,15% en la muestra de testeo. Podemos comparar este resultado con Korol (2013), que ofrece un porcentaje de clasificación del 74,07%. Por lo que se refiere a la muestra de América para t-2, nuestro modelo clasificó correctamente un 87,26% de las empresas de la muestra, situándose por encima del modelo de Altman et al. (2017) que registró un poder de clasificación del 70,1%. Las únicas variables comunes encontradas con estos estudios son las V1 y V3.

Por su parte, los modelos desarrollados en el presente trabajo con PMC obtuvieron unos porcentajes de acierto superiores a los modelos Logit del estudio Alaminos, del Castillo y Fernández (2016), demostrando la superioridad de las técnicas computacionales frente a los métodos estadísticos, tal y como sugiere la literatura previa sobre predicción de quiebra. De igual forma, mostraron un mejor rendimiento en la validación cruzada con el uso del modelo global en todas las regiones estudiadas. Y también el conjunto de variables significativas para cada caso arrojó algunas diferencias respecto a los modelos Logit citados. En el modelo de Asia con Logit, las variables significativas fueron V1, V4, V5 y V8, mientras que con PMC las variables han sido V1 y V8. Para el modelo de Europa, en el caso de Logit las variables fueron V2, V4, V5, V8 y V9, y para PMC las variables son V3, V4, V5, V8 y V9. Por último, para el modelo de América, en el caso de Logit las variables fueron V3, V5, V6 y V8, mientras que con PMC se añadió la variable V1.

CONCLUSIONES

El presente trabajo de investigación trata de cubrir el hueco existente en la literatura en relación con la posible superioridad de los modelos globales frente a los regionales (o de un solo país) a la hora de predecir la quiebra empresarial. Se ha tratado de aclarar esta cuestión, superando la ausencia previa de conclusiones definitivas debida a la falta de homogeneidad provocada por la disparidad de metodologías, enfoques, bases de datos disponibles, periodos temporales y países, entre otros asuntos.

Para aclarar este objetivo, a partir de la base de datos COMPUSTAT (Standard & Poor's), se ha tomado una muestra amplia formada tanto por empresas quebradas como no quebradas pertenecientes a tres regiones: Asia, Europa y América. Los datos utilizados para este estudio se corresponden al período comprendido entre el año 1990 y el año 2013. Se han construido modelos regionales y modelos globales utilizando información de un año y dos años antes de la quiebra ($t-1$ y $t-2$). A tal efecto, se han considerado un total de 220 y 218 empresas en situación de quiebra, para $t-1$ y $t-2$, respectivamente.

Para la obtención de los modelos, la metodología aplicada ha sido el PMC, que emplearon 11 variables financieras y variables dummies representativas de las regiones consideradas. Con esta estructura, se ha obtenido un poder de clasificación de hasta el 95,26% (Europa en $t-1$).

Los resultados empíricos obtenidos nos han permitido confirmar la hipótesis H_1 , que cuestionaba la existencia de diferencias entre los modelos globales y los regionales, y que han evidenciado que los modelos globales son modelos diferentes a los regionales, pues las variables que contienen son diferentes, aun siendo algunas comunes. Esta hipótesis ha sido aceptada tanto para $t-1$ como para $t-2$.

Asimismo, y en relación con hipótesis H_2 , que postulaba que la introducción de una variable dummy regional en los modelos globales, que recogiese la probabilidad inobservada de las regiones, mejoraba dichos modelos; la evidencia empírica ha permitido aceptarla tanto para $t-1$ como para $t-2$, todo ello a tenor de la comparación efectuada mediante los criterios de Akaike, Schwartz y Hannan-Quinn.

Finalmente, y en relación con la hipótesis H_3 relativa a si el modelo global era capaz de predecir correctamente con las muestras de las diferentes regiones, la evidencia empírica también ha mostrado que es aceptada tanto $t-1$ como para $t-2$. Para ello se han tenido en cuenta los resultados obtenidos durante el proceso la validación cruzada y en la aplicación de los criterios de selección de modelos.

Con respecto a las variables explicativas, en todos los modelos regionales estimados aparecieron como significativas algunas variables de manera continua a lo largo del horizonte temporal en cada región. Pero tanto en modelos regionales como globales, la importancia de la naturaleza de las variables ha seguido un patrón similar. Así, las variables de rentabilidad han tenido una mayor importancia para $t-1$ y las variables de rentabilidad y liquidez para $t-2$.

Como resultado de las conclusiones anteriores creemos que el presente trabajo de investigación contribuye al conocimiento financiero empresarial a la hora de abordar una estrategia de predicción de la quiebra en diferentes regiones. En todos los casos, el modelo global desarrollado es capaz de predecir con éxito la quiebra en muestras de empresas pertenecientes a regiones específicas, lo que significaría un ahorro de costes considerable en el desarrollo de diferentes modelos regionales. Además, los modelos construidos con PMC han resultado ser una continuación mejorada de los modelos Logit desarrollados en el estudio de Alaminos, del Castillo y Fernández (2016), en tanto que

confirman, de una manera más robusta, la existencia de modelos globales con capacidad explicativa. Por último, y dado que el primer paso en la gestión de los riesgos es realizar una medición de los mismos, una adecuada puntuación del riesgo de quiebra puede ayudar en este sentido. Por ello, antes de la decisión de utilizar un determinado modelo, la empresa necesita fundamentos que le orienten en las limitaciones de éstos y sobre cuál de ellos (globales o regionales) se adapta mejor a sus circunstancias.

Nuestra evidencia ayuda también a explicar que el proceso de globalización puede influir en los factores financieros de las empresas que provocan la quiebra. Estas conclusiones pueden ser importantes cuando se minimiza el coste de construir modelos de predicción de quiebra, dada la existencia de variables financieras explicativas que son comunes a las regiones más importantes del mundo. Además, y debido al poder de generalización demostrado por el modelo global, enfatizamos la necesidad de que las firmas multinacionales administren sus propios modelos de predicción de quiebra, aplicándolos a clientes, proveedores y a las empresas en las que tienen participaciones. Por último, la existencia de un modelo global de predicción de quiebra también puede cumplir los requisitos de las "Normas Internacionales de Auditoría" con respecto al principio de empresa en funcionamiento (going-concern), que propone el uso de modelos de viabilidad para las empresas con el fin de respaldar las opiniones de los auditores en el contexto del riesgo de insolvencia.

Como todas las investigaciones, este estudio tiene algunas limitaciones, principalmente la disponibilidad de datos de empresas en países emergentes. Dado que se trata de una investigación realizada desde una perspectiva global, requiere un alcance de información mucho mayor en comparación con otros estudios realizados en este campo. Además, la investigación futura podría seguir un enfoque para

investigar qué condiciones macroeconómicas afectan al comportamiento de las variables financieras que han demostrado ser buenos predictores de quiebra en esta tesis. Asimismo, y para aumentar la capacidad de generalización de los resultados, se podrían incluir datos de otro tipo de empresas (por ejemplo, pequeñas y medianas empresas).

Finalmente, y como consecuencia de los resultados del presente estudio, pensamos que surgen futuras líneas de investigación de suma utilidad para perfeccionar los modelos de predicción de quiebra. Entre ellas, sería interesante comprobar si las conclusiones obtenidas pueden ser generalizables con la extensión de la definición de quiebra a la de dificultades financieras, también muy empleada por la literatura previa sobre predicción de insolvencia.

BIBLIOGRAFÍA GENERAL

Agarwal, V. y Taffler, R. (2008). Comparing the performance of market based and accounting-based bankruptcy prediction models. *Journal of Banking and Finance*, 32, 1541–1551.

Aggarwal, R. y Goodell, J.W. (2014). Cross-national differences in access to finance: Influence of culture and institutional environments. *Research in International Business and Finance*, 31, 193-211.

Ahn H. y Kim, K. (2009). Bankruptcy prediction modelling with hybrid case-based reasoning and genetic algorithms approach. *Application Software Computing*, 9, 599–607.

Akaike, H. (1973). Information theory and an extension of the maximum likelihood principle. In B. N. Petrov and F. Csaki (Eds.), *Second international symposium on information theory*, 267-281.

Alaka, H.A., Oyedele, L.O., Owolabi, H.A., Oyedele, A.A., Akinade, O.O., Bilal, M. y Ajayi, S.H. (2017). Critical factors for insolvency prediction: towards a theoretical model for the construction industry. *International Journal of Construction Management*, 17 (1), 25-49.

Alaminos, D., del Castillo, A. y Fernández, M.Á. (2016) A global model for bankruptcy prediction. *PLoS ONE* 11(11): e0166693.

Alaminos, D., del Castillo, A., y Fernández, M.Á. (2019). Predicción de opinión going concern en clubes de fútbol: Evidencia para la Liga Española. *Contaduría y Administración*, Próximos Artículos.

Alfaro, E., García, N., Gámez, M. y Elizondo, D. (2008). Bankruptcy forecasting: An empirical comparison of AdaBoost and neural networks. *Decision Support Systems*, 45, 110-122.

Allen, D.M. (1974). The relationship between variable selection and data augmentation and a method for prediction. *Technometrics*, 16, 125-127.

Altman, E.I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance*, 23 (4), 589-609.

Altman, E.I. (1993). *Corporate Financial Distress and Bankruptcy*. 2nd ed. New York. John Wiley & Sons.

Altman, E.I., Iwanicz-Drozowska, M., Laitinen, E.K. y Suvas, A. (2017). Financial distress prediction in an International context: A review and empirical analysis of Altman's Z-Score model. *Journal of International Financial Management & Accounting*, 2, 131-171.

Anandarajan, M., Lee, P. y Anandarajan, A. (2001). Bankruptcy prediction of financially stressed firms: An examination of the predictive accuracy of artificial neural networks. *Intelligent Systems in Accounting, Finance and Management* 10, 69-81.

Antunes, F., Ribeiro, B. y Pereira, F. (2017). Probabilistic modelling and visualization for bankruptcy prediction. *Applied Soft Computing*, 60, 831-843.

Arquero, J.L., Abad, M.C. y Jiménez, S.M. (2009). Procesos de fracaso empresarial en Pymes. Identificación y contrastación empírica. *Revista Internacional de la Pequeña y Mediana Empresa*, 2 (1), 64-77.

Atiya, A.F. (2001). Bankruptcy prediction for credit risk using neural network: A survey and new results. *IEEE Transactions on Neural Networks*, 12 (4), 929-935.

Back, B., Laitinen, T. y. Sere, K. (1996). Neural networks and genetic algorithms for bankruptcy predictions. *Expert Systems with Applications*, 11, 407-413.

Balcaen, S. y Ooghe, H. (2006). 35 years of studies on business failure: an overview of the classic statistical methodologies and their related problems. *British Accounting Review*, 38, 63-93.

Baldwin, J. y Glezen, G.W. (1992). Bankruptcy prediction using quarterly financial statement data. *Journal of Accounting, Auditing and Finance*, 7, 269-289.

Bauer, J. and Agarwal, V. (2014). Are hazard models superior to traditional bankruptcy prediction approaches? A comprehensive test. *Journal of Banking and Finance* 40, 432-442.

Barboza, F., Kimura, H. y Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83 (15), 405-417.

Bartoloni, E. y Baussola, M. (2014). Financial performance in manufacturing firms: A comparison between parametric and non-parametric approaches. *Business Economics*, 49 (1), 32-45.

Basheer, I.A. y Hajmeer, M. (2000). Artificial Neural Networks: fundamentals, computing, design and application. *Journal of Microbiological Methods*, 43, 3-41.

Beaver WH (1966). Financial ratios as predictors of failure. *Journal of Accounting Research*, 4, Empirical Research in Accounting, 71-111.

Bellovary J.L., Giacomino D.E. y Akers M.D. (2007) A review of bankruptcy prediction studies: 1930 to present. *Journal of Financial Education*, 33 (4), 3-41.

Berg, D. (2007). Bankruptcy prediction by generalized additive models. *Applied Stochastic Models in Business and Industry* 23, 129-143.

Bernardos, P.G. y Vosniakos, G.C. (2007). Optimizing feedforward artificial neural network architecture. *Engineering Applications of Artificial Intelligence*, 20 (3), 365-382

Bernstein, L.A. (1984). *Análisis de Estados Financieros*. Ed. Deusto. Bilbao.

Betz, F., Oprica, S., Peltonen, T.A. y Sarlin, P. (2014). Predicting distress in European banks. *Journal of Banking & Finance*, 45, 225-241.

Bharath, S.T. y Shumway, T. (2008). Forecasting default with the Merton distance to default model," *Review of Financial Studies*, 21, 1339-1369.

Borrajo, M., Baruque, B., Corchado, E., Bajo, J. y Corchado, J. (2011). Hybrid neural intelligent system to predict business failure in small-to-medium-size enterprises. *International Journal Neural Systems*, 21, 4, 277-296.

Bose, I. y Pal, R. (2006). Predicting the survival or failure of click-and-mortar corporations: a knowledge Discovery approach. *European Journal of Operations Research*, 174, 959-982.

Bradley, A.P. (1997). The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30 (7), 1145-1159

Brezigar-Masten, A. y Masten, I. (2012). CART-based selection of bankruptcy predictors for the logit model. *Expert Systems with Applications*, 39 (11), 10153-10159.

Bruneaua, C., de Bandtb, O. y. El Amria, W. (2012). Macroeconomic fluctuations and corporate financial fragility. *Journal of Financial Stability*, 8, 219–235.

Callejón, A.M., Casado, A.M., Fernández, M.A. y Peláez, J.I. (2013). A system of insolvency prediction for industrial companies using a financial alternative model with neural networks. *International Journal of Computational Intelligence Systems*, 4, 1-13.

Charalambous, C., Charitou, A. y Kaourou, F. (2000). Comparative analysis of artificial neural network models: Application in bankruptcy prediction. *Annals of Operations Research*, 99, 403-425.

Charitou, A., Neophytou, E. y Charalambous, C. (2004). Predicting corporate failure. Empirical evidence for the UK. *European Accounting Review*, 13 (3), 465–497.

Chaudhuri, A. y De, K. (2011). Fuzzy support vector machine for bankruptcy prediction. *Applied Soft Computing*, 11, 2472-2486.

Chauhan, N., Ravi, V., Chandra, D.K. (2009). Differential evolution trained wavelet neural networks: Application to bankruptcy prediction in banks. *Expert Systems with Applications*, 36(4), 7659-7665.

Cheng, S. y Pecht, M. (2012). Using cross-validation for model parameter selection of sequential probability ratio test. *Expert Systems with Applications*, 39, 8467–8473.

Chen, H.L., Yang, B., Wang, G., Liu, J., Xu, X., Wang, S.J., y Liu, D.Y. (2011). A novel bankruptcy prediction model based on an adaptive fuzzy k-nearest neighbor method. *Knowledge-Based Systems*, 24 (8), 1348-1359.

Cho, S., Hong, H. y Ha, B.C. (2010). A hybrid approach based on the combination of variable selection using decision trees and case-based reasoning using the Mahalanobis distance: For bankruptcy prediction. *Expert Systems with Applications*, 4, 3482-3488.

Chong, A.Y.L. (2013). Predicting m-commerce adoption determinants: A neural network approach. *Expert Systems with Applications*, 40 (2), 523-530

Chou, C.H., Hsieh, S.C. y Qiu, C.J. (2017). Hybrid genetic algorithm and fuzzy clustering for bankruptcy prediction. *Applied Soft Computing*, 56, 298-316.

Chung, C.C., Chen, T.S., Lin, L.H. y Lin, Y.C. (2016). Bankruptcy prediction using cerebellar model neural networks. *International Journal of Fuzzy Systems*, 18 (2), 160–167.

Cielen, A., Ludo, P. y Vanhoof, K. (2004). Bankruptcy prediction using a data envelopment analysis. *European Journal of Operations Research*, 154, 526–532.

Coats, P.K., y Fant, L.F. (1993). Recognizing financial distress patterns using a neural network tool. *Financial Management*, 22 (3), 142-155.

Collins, R.A. (1980). An empirical comparison of bankruptcy prediction models. *Financial Management*, 9 (2), 52-57

Das, S.R., Hanouna P. y Sarin. A. (2009). Accounting-based versus market-based cross-sectional models of CDS spreads. *Journal of Banking and Finance* 33, 719-730.

Deakin, E.B. (1972). A discriminant analysis of predictors of business failure. *Journal of Accounting Research*, 10 (1), 167-179.

Diamond, J.H. (1976). Pattern recognition and the detection of corporate failure. PhD. Dissertation, New York University.

Ding, Y., Song, X. y Zeng, Y. (2008). Forecasting financial condition of Chinese listed companies based on support vector machine. *Expert Systems with Applications*, 34, 3081-3089.

Dimitras, A., Zanakis, S. y Zopounidis, C. (1996). A survey of business failures with an emphasis on prediction methods and industrial applications. *European Journal of Operations Research*, 90, 487-513.

DuJardin, P. (2018). Failure pattern-based ensembles applied to bankruptcy forecasting. *Decision Support Systems*, 107, 64-77.

Edminster, R. (1972). An empirical test of financial ratio analysis for small business failure prediction. *Journal of Financial and Quantitative Analysis*, 7 (2), 1477-1493.

El Hennawy, R. y Morris, R. (1983). The significance of base year in developing failure prediction models. *Journal of Business Finance and Accounting*, 10 (2), 209-223.

El-Temtamy, O. (1995). Bankruptcy prediction: A comparative study on logit and neural networks. PhD Dissertation. Middle Tennessee University.

Etemadi, H., Rostamy, A. y Dehkordi, H. (2009). A genetic programming model for bankruptcy prediction: empirical evidence from Iran. *Expert Systems Applications*, 36 (2), 3199–3207.

Evans, J. y Borders, A.L. (2014). Strategically surviving bankruptcy during a global financial crisis: The importance of understanding chapter 15. *Journal of Business Research*, 67 (1), 2738-2742.

Fernández, M.A., Gil, A.M. y López, P. (2009). Estructura y Equilibrio financiero de las PYMES Españolas ante las Nuevas Exigencias de Información Financiera. Fundación de las Cajas de Ahorros. Madrid.

Figlewski, S., Frydman, H. y Liang, W. (2012). Modeling the effect of macroeconomic factors on corporate default and credit rating transitions. *International Review of Economics & Finance*, 21 (1), 87-105.

Fletcher, D. y Goss, E. (1993). Forecasting with neural networks. An application using bankruptcy data. *Information and Management*, 24, 159-167.

Flórez, R. y Fernández, J.M. (2008). Las Redes Neuronales Artificiales. Fundamentos teóricos y aplicaciones prácticas. Ed. Netbiblo. Coruña.

Friedman, H., Altman, E.I. y Kao, D. (1985). Introducing recursive partitioning for financial classification: the case of financial distress. *Journal of Finance*, 40, 269–291.

García, V. y Fernández, M.A. (1992). Solvencia y Rentabilidad de la Empresa Española. Instituto de Estudios Económicos. Madrid.

Gepp, A., Kumar, K. y Bhattacharya, S. (2010). Business failure prediction using decision trees. *Journal of Forecasting* 29, 536-555.

Geisser, S. (1975). The predictive sample reuse method with applications. *Journal of American Statistical Association*, 70, 320–328.

Gesel, T., Baesens, B., Suykens, J., Poel, D., Baestaens, D. y Willekens, M. (2006). Bayesian kernel based classification for financial distress detection. *European Journal of Operations Research*, 172, 979–1003.

Giordani, P., Jacobson, T., von Schedvin, E. y Villani, M. (2014). Taking the twists into account: Predicting firm bankruptcy risk with splines of financial ratios. *Journal of Financial and Quantitative Analysis*, 49, 1071-1099.

Global Industry Classification Standard (GICS). Standard & Poor's y Morgan Stanley Capital International (<https://www.unm.edu/~maj/Security%20Analysis/GICS.pdf>)

Guan, Q. (1993). Development of optimal network structures for back-propagation-trained neural networks. PhD dissertation. University of Nebraska.

Graupe, D. (2013). Principles of Artificial Neural Networks. 3rd Edition. Advanced Series in Circuits and Systems. World Scientific

Grüenberg, M. y O. Lukason (2014). Predicting bankruptcy of manufacturing firms. International Journal of Trade, Economics and Finance, 5 (1), 93-97.

Hair, J. (2008). Análisis Multivariante; Editorial Prentice Hall.

Hannan, E.J. y Quinn, B.G. (1979). The determination of the order of an autoregression. Journal of the Royal Statistical Society, Series B, 41 (2), 190-195.

Han, J. (2002). Application of Artificial Neural Networks for Flood Warning Systems. Doctoral Dissertation: PhD in Civil/Environmental Engineer from North Carolina State University.

Hauser, R.P. y Booth, D. (2011). Predicting bankruptcy with robust logistic regression. Journal of Data Science, 9, 565-584.

Hashem, S. (1992). Sensitivity analysis for feedforward artificial neural networks with differentiable activation functions. International Joint Conference on Neural Networks, 419-424.

Hastie, T., Tibshirani, R. y Friedman, J. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer, New York.

Haykin, S. (1999). *Neural Networks. A Comprehensive Foundation*. 2ª edición. Prentice-Hall, New Jersey.

Hecht-Nielsen, R. (1987). Neurocomputing: Pricking the Human Brain. *IEEE Spectrum*, 25, 36-41.

Hecht-Nielsen, R. (1990). *Neurocomputing*. Addison Wesley. Nueva York.

Hensher, D. y Jones, S. (2007). Forecasting corporate bankruptcy: Optimizing the performance of the mixed logit model. *Abacus*, 43 (3), 241-364.

Hilera, J.R. y Martínez, V.J. (1995). *Redes Neuronales Artificiales. Fundamentos, Modelos y Aplicaciones*. Ed. Ra-Ma. Madrid.

Hwang, R., K. F. Cheng, K.F. y Lee, J.C. (2007). A semiparametric method for predicting bankruptcy. *Journal of Forecasting*, 26, 317-342.

Izan, H. (1984). Corporate distress in Australia. *Journal of Banking and Finance*, 8, 303-320.

Jabeur, B.S. (2017). Bankruptcy prediction using Partial Least Squares Logistic Regression. *Journal of Retailing and Consumer Services*, 36(C), 197-202.

Jo, H. y Han, I. (1996). Integration of case-based forecasting, neural network, and discriminant analysis for bankruptcy prediction. *Expert Systems with Applications*, 11, 415-422.

Jo, H. y Han, I. (1997). Bankruptcy prediction using casebased reasoning, neural networks, and discriminant analysis. *Expert Systems with Applications*, 13, 97–108.

Jones, S. Johnstone, D. y Wilson, R. (2017). Predicting corporate bankruptcy: An evaluation of alternative statistical frameworks. *Journal of Business Finance & Accounting*, 44 (1-2), 3-34.

Jones, S. y Hensher, D.A. (2007). Forecasting corporate bankruptcy: Optimizing the performance of the mixed logit model. *Abacus*, 43, 241–264.

Keener, M. (2013). Predicting the financial failure of retail companies in the United States. *Journal of Business and Economics Research*, 11 (8), 373-380.

Kim, H.J., Jo, N.O. y Shin, K.S. (2016). Optimization of cluster-based evolutionary undersampling for the artificial neural networks in corporate bankruptcy prediction. *Expert Systems with Applications*, 59 (15), 226-234

Kluger, B.D. y Shields, D. (1989). Auditor changes, information quality and bankruptcy prediction. *Managerial and Decision Economics*, 10 (4), 275-282.

Kolmogorov, A.N. (1957). On the representations of continuous functions of many variables by superpositions of continuous functions of one variable and addition. *Doklady Akademii Nauk USSR*, 114(5), 953-956.

Korol, T. (2013). Early warning models against bankruptcy risk for Central European and Latin American enterprises. *Economic Modelling*, 31, 22-30.

Kuan, C.M. y White, H. (1994). Artificial Neural Network: An econometric perspective. *Econometric Reviews*, 13, 1-91

Kwak, W., Shi, Y. y Kou, G. (2011). Bankruptcy prediction for Korean firms after the 1997 financial crisis: using a multiple criteria linear programming data mining approach. *Review of Quantitative Finance and Accounting*, 38 (4), 441-453.

Hopwood, W., McKeown, J. y Mutchler, J. (1989). A test of the incremental explanatory power of opinions qualified for consistency and uncertainty. *The Accounting Review*, 44 (1), 28-48.

Hui, X. F., y Sun, J. (2006). An application of support vector machine to companies financial distress prediction. *Lecture Notes. Artificial Intelligent*, 3885, 274-282.

Laitinen, E.K. y Laitinen, T. (2000). Bankruptcy prediction application of the Taylor's expansion in logistic regression. *International Review of Financial Analysis*, 9, 327-349.

Laitinen, E.K. y Suvas, A. (2013). International applicability of corporate failure risk models based on financial statement Information: Comparisons across European countries. *Journal of Finance & Economics*, 1 (3), 1-26.

Lee, S. y Choi, W.S. (2013). A multi-industry bankruptcy prediction model using backpropagation neural network and multivariate discriminant analysis. *Expert Systems with Applications*, 40, 2941-2946.

Ley 22/2003 de 9 de Julio, Concursal.

Li, H., Huang, H., Sun, J. y Lin, C. (2010). On sensitivity of case-based reasoning to optimal feature subsets in business failure prediction. *Expert System with Applications*, 37 (7), 4811-4821.

Li, H., Lee, Y., Zhou, Y. y Sun, J. (2011). The random subspace binary logit (RSBL) model for bankruptcy prediction. *Knowledge-Based Systems*, 24, 1380-1388.

Lin, F., Yeh, C.C. y Lee, M.Y. (2011). The use of hybrid manifold learning and support vector machines in the prediction of business failure. *Knowledge-Based Systems*, 24, 95-101.

Lisboa, P., Mehridehnavi, A. y Martin, P. (1994). The interpretation of supervised neural networks. *Proceedings of the Workshop on Neural Network Applications and Tools*, 11-17.

Liu, J. (2004) Macroeconomic determinants of corporate failures: evidence from the UK, *Applied Economics*, 36 (9), 939-945

López, M. y López, J. (1996). *Estadística para actuarios*. Editorial Mapfre, Madrid.

Maghyereh, A.I. y Awartani, B. (2014). Bank distress prediction: Empirical evidence from the Gulf Cooperation Council countries. *Research in International Business and Finance*, 30, 126-147.

Martín del Brio, B. y Sanz, A. (2001). Redes neuronales y sistemas borrosos. Ed. Ra-Ma. Madrid.

McKee, T.E. (2000). Developing a bankruptcy prediction model via rough sets theory. *Intelligent Systems in Accounting, Finance and Management*, 9, 159-173.

McKee, T.E. y Greenstein, M. (2000) Predicting bankruptcy using recursive partitioning and a realistically proportioned data set. *Journal of Forecasting*, 3, 219-230.

McKee, T.E. y Lensberg, T. (2002). Genetic programming and rough sets: A hybrid approach to bankruptcy classification. *European Journal of Operational Research*, 138, 436-451.

Mensah, Y.M. (1983). The Differential Bankruptcy Predictive Ability of Specific Price Level Adjustments: Some Empirical Evidence. *The Accounting Review*, 58 (2), 228-246.

Messier Jr., W. F., y Hansen, J. (1988). Inducing rules for expert system development: An example using default and bankruptcy data. *Management Science*, 34 (12), 1403- 1415.

Meyer, P. y Pifer, H. (1970). Prediction of bank failures. *Journal of Finance*, 25 (4), 853-868.

Min, J.H. y Lee, Y. (2005). Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert Systems with Applications* 28, 603-614.

Minsky, M.L. y Papert, S.A. (1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press. Cambridge.

Mossman, C.E., Bell, G.G., Swartz, M.L. y Turtle, H. (1988). An empirical comparison of bankruptcy models. *The Financial Review*, 33 (2), 35-54

Müller, B. y Reinhardt, J. (1990). *Neural Networks: An Introduction*. Springer Science & Business Media.

Müller, B., Reinhardt, J. y Strickland, M.K. (2012). *Neural Networks: An Introduction*. Springer Science & Business Media.

Mulford, C.W. y Comiskey, E.E. (2005). *Creative cash-flow reporting. Uncovering Sustainable Financial Performance*. John Wiley and Sons. New Jersey, 316 y ss.

Núñez de Castro, L. y Von Zuben, F. J. (1998). Optimised training techniques for feedforward neural networks. Technical Report DCA -RT 03/98. Department of Computer Engineering and Industrial Automation. FEE/UNICAMP, Brasil.

Park, C. S. y Han, I. (2002). A case-based reasoning with the feature weights derived by analytic hierarchy process for bankruptcy prediction. *Expert Systems with Applications*, 23, 255–264.

Pendharkar, P.C. (2002). A potential use of data envelopment analysis for the inverse classification problem. *Omega*, 30 (3), 243-248.

Peña, D. (2002). *Análisis de datos multivariantes*. Ed. Mc Graw Hill. Madrid.

Pindado, J. Rodrigues, L. y De la Torre, C. (2008). Estimating financial distress likelihood. *Journal of Business Research*, 61, 995-1003.

Platt, H.D. y Platt, M.B. (2008). Financial distress comparison across three global regions. *Journal of Risk and Financial Management*, 1(1), 129-162.

Pompe, P. y Bilderbeek, J. (2005). Bankruptcy prediction: The influence of the year prior to failure selected for model building and the effects in a period of economic decline. *International Journal of Intelligent Systems in Accounting and Finance Management*, 13, 95-112.

Premachandra, I.M., Chen, Y. y Watson, J. (2011). DEA as a tool for predicting corporate failure and success: a case of bankruptcy assessment. *Omega*, 39 (6), 620-626.

Odom, M. y Sharda, R. (1990). A neural network model for bankruptcy prediction. *Proceedings of the IEEE International Conference on Neural Networks*, 2, 163-168.

Ohlson, J. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18 (1), 109-131.

Ouenniche, J., Bouslah, K., Cabello, J.M. y Ruiz, F. (2017). A new classifier based on the reference point method with application in bankruptcy prediction. *Journal of the Operational Research Society*, 6, 1-8.

Ouenniche, J. y Tone, K. (2017). An out-of-sample evaluation framework for DEA with application in bankruptcy prediction. *Annals of Operations Research*, 254 (1–2), 235–250.

Oz, I.O. y Yelkency, T. (2017). A theoretical approach to financial distress prediction modeling. *Managerial Finance*, 43(2), 212-230.

Rafiei, F.M., Manzari, S.M. y Bostanian, S. (2011). Financial health prediction models using artificial neural networks, genetic algorithm and multivariate discriminant analysis: Iranian evidence. *Expert Systems with Applications*, 38, 10210–10217.

Ravi, V. y Krishna, M. (2014). A new online data imputation method based on general regression auto associative neural network. *Neurocomputing*, 138, 106-113.

Ravisankar, P. y V. Ravi (2010). Financial distress prediction in banks using Group Method of Data Handling neural network, counter propagation neural network and fuzzy ARTMAP. *Knowledge-Based Systems*, 23, 823–831.

Ravisankar, P., Ravi, V. y Bose, I. (2010). Failure prediction of dotcom companies using neural network–genetic programming hybrids. *Information Sciences*, 180 (8), 1257-1267

Ribeiro, B., Silva, C., Chen, N., Vieira, A. y das Neves, J.C. (2012). Enhanced default risk models with SVM+. *Expert Systems with Applications*, 39, 10140-10152.

Russel, S.J. y Norvig, P. (2004). *Inteligencia Artificial. Un enfoque moderno*, Ed. Pearson Educación. Madrid, 838-851.

Ryu, Y. y Yue, W. (2005). Firm bankruptcy prediction: experimental comparison of isotonic separation and other classification approaches. *IEEE Trans. Syst. Man Cybern– Part A: Systems Humans*, 21 (4), 265–276.

Santomero, A. y J. Vinso (1977). Estimating the probability of failure for comercial banks and the banking system. *Journal of Banking and Finance*, 1 (2), 185-205.

Sarkar, S. y R.S. Sriram (2001). Bayesian models for early warning of bank failures. *Management Science*, 47 (11), 1457–1475.

Schwarz, G. (1978). Estimating the dimension of a model. *Annalsof Statistics*, 6, 461-464.

Serrano-Cinca, C. y B. Gutiérrez-Nieto (2013). Partial Least Square Discriminant Analysis for bankruptcy prediction. *Decision Support Systems*, 3, 1245-1255.

Simons, D. y Rolwes, F. (2009). Macroeconomic Default Modeling and Stress Testing. *International Journal of Central Banking*, 5 (3), 177-204.

Shang, Y., y Wah, B.W., (1996). Global optimization for neural network training. *Computer*, 29(3), 45-54.

Shin, K. y Lee, Y. (2002). A genetic algorithm application in bankruptcy prediction modeling. *Expert Systems with Applications* 23, 321-328.

Shin, K., Lee, T.L. y Kim, H. (2005). An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28, 127-135.

Shumway, T. (2001). Forecasting bankruptcy more accurately: A simple hazard model. *The Journal of Business*, 74, 101-124.

Smaraanda, C. (2014). Scoring functions and bankruptcy prediction models case study for Romanian companies. *Procedia Economics and Finance*, 10, 217-226.

Stone, M. (1974). Cross-validation choice and assessment of statistical predictions. *Journal of the Royal Statistical Society: Series B*, 36, 111-147.

Sun, J. y Li, H. (2008). Listed companies financial distress prediction based on weighted majority voting combination of multiple classifiers. *Expert Systems with Applications*, 35, 818-827.

Sun, J., Li, H., Huang, Q.H. y He, K.Y. (2014). Predicting financial distress and corporate failure: A review from the state-of-the-art definitions, modeling, sampling, and featuring approaches. *Knowledge-Based Systems*, 57, 41-56.

Sun, L. y Shenoy; P. (2007). Using Bayesian networks for bankruptcy prediction: Some methodological issues. *European Journal of Operations Research*, 180, 738-753.

Taffler, R.J. (1984). Empirical Models for the Monitoring of UK Corporations. *Journal of Banking and Finance*, 8, 199-227.

Takane, Y. (1987). Introduction to special section. *Psychometrika*, 52, 3, 316-316.

Tam, K. (1991). Neural network models and the prediction of bank bankruptcy. *Omega*, 19 (5), 429-445.

Tam, K. y Kiang, M. (1992). Managerial applications of neural networks: the case of bank failure prediction. *Management Science*, 38 (7), 926-947.

Teixeira, J.P. (2004). A Prosody Model to TTS Systems. Doctoral Dissertation; PhD in Electrotechnical and Computer Engineering from Faculty of Engineer of Porto University.

Theodossiou, P. (1993). Predicting shifts in the mean of a multivariate time series process: An application in predicting business failures. *Journal of the American Statistical Association*, 88 (422), 441-449.

Tinoco, M.H. y Wilson, N. (2013). Financial distress and bankruptcy prediction among listed companies using accounting, market and macroeconomic variables. *International Review of Financial Analysis*, 30, 394-419.

Tsai, C. (2009). Feature selection in bankruptcy prediction. *Knowledge-Based Systems*, 22 (2), 120-127.

Tsai, C., Hsu, Y. y Yen, D.C. (2014). A comparative study of classifier ensembles for bankruptcy prediction. *Applied Soft Computing*, 24, 977-984.

Tseng, F. y Hu, Y. (2010). Comparing four bankruptcy prediction models: Logit, quadratic interval logit, neural and fuzzy neural networks. *Expert Systems with Applications*, 37, 1846-1853.

Tsukuda, J. y Baba, S. (1994). Predicting Japanese corporate bankruptcy in terms of financial data using neural network. *Computers and Industrial Engineering*, 27, 445-448.

U.S. Code: Title 11 - BANKRUPTCY | US Law.

Varetto, F. (1998). Genetic algorithms applications in the analysis of insolvency risk. *Journal of Banking and Finance*, 22, 1421-1439.

Vavrina, J., Hampel, D. y Janová, J. (2013). New approaches for the financial distress classification in agribusiness. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, LXI (4), 1177-1182.

Vassalou, M. y Xing, Y., (2004). Default risk in equity returns. *The Journal of Finance*, 59(2), 831-868.

Visauta, B. (2003). *Análisis Estadístico con SPSS para Windows*, Vol. II. E. McGraw-Hill.

Wang, Y., Wang, S. y K.K. Lai (2005). A new fuzzy support vector machine to evaluate credit risk. *IEEE Transactions on Fuzzy Systems*, 13 (6), 820-831.

Wasilewski, M. y Madra, M. (2008). An assessment of the agricultural enterprises' solvency with the usage of the Altman Model. *Acta Oeconomica et Informatica*, 2, 50-55.

Wu, W. (2011). Improving classification accuracy and causal knowledge for better credit decisions. *International Journal of Neural Systems*, 21 (4), 297–309.

Yang, Z. R., Platt, M. B. y H.D. Platt (1999). Probabilistic neural networks in bankruptcy prediction. *Journal of Business Research*, 44, 67–74.

Yang, Z., You, W. y Ji, G. (2011). Using partial least squares and support vector machines for bankruptcy prediction. *Expert Systems with Applications*, 38, 8336-8342.

Yao, J., Li, Y. y Tan, C.H. (2000). Option price forecasting using neural networks. *Omega, The International Journal of Management Science*, 28, 455-466.

Yeh, C. C., Chi, D. J. y Hsu, M.F (2010). A hybrid approach of DEA, rough set and support vector machines for business failure prediction. *Expert Systems with Applications*, 37, 1535–1541.

Zavgren, C.V. (1985). Assessing the vulnerability to failure of American industrial firms. *Journal of Business and Accounting*, 12 (1), 19-45.

Zemouri, R., Racocceanu, D. y Zerhouni, N. (2003). Recurrent radialbasis function network for time-series prediction. *Engineering Applications of Artificial Intelligence*, 16, 453-463.

Zhang, G., Hu, M.Y., Patuwo, B.E. y Indro, D.C. (1999). Artificial neural networks in bankruptcy prediction: General framework and cross validation analysis. *European Journal of Operations Research*, 116 (1), 16-33.

Zhou L (2013) Performance of corporate bankruptcy prediction models on imbalanced dataset: The effect of sampling methods. *Knowledge-Based Systems*, 41, 16-25.

Zhang, Y. y Yang, Y. (2015). Cross-validation for selecting a model selection procedure. *Journal of Econometrics*, 187, 95–112.

Zhou, L. y Lai, K.K. (2017). AdaBoost models for corporate bankruptcy prediction with missing Data. *Computational Economics*, 50 (1), 69–94

Zhou, L., Tam, K.P., y Fujita, H. (2016). Predicting the listing status of Chinese listed companies with multi-class classification models. *Information Sciences*, 328, 222-236.

Zmijewski, M.E. (1984). Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting Research*, 22, 59-81.